

Vysoká škola báňská – Technická univerzita Ostrava

Fakulta elektrotechniky a informatiky

Katedra kybernetiky biomedicínského inženýrství

**SW pro automatickou analýzu a modelování
myokardu z MOLLI
sekvencí**

**SW for Automatic Analysis and Modeling of
Myocardium from MOLLI
Sequence**

Student: Vojtěch Raška

Vedoucí bakalářské práce: doc. Ing. Martin Augustynek, Ph.D.

Studijní obor: Biomedicínské inženýrství

Datum zadání diplomové práce: 01.09.2019

Termín odevzdání diplomové práce: 30.04.2020

Zadání diplomové práce

Student: **Bc. Vojtěch Raška**
Studijní program: N2649 Elektrotechnika
Studijní obor: 3901T009 Biomedicínské inženýrství
Téma: **SW pro automatickou analýzu a modelování myokardu
z MOLLI sekvencí
SW for Automatic Analysis and Modeling of Myocardium
from MOLLI Sequence**
Jazyk vypracování: čeština

Zásady pro vypracování:

1. Nastudování problematiky snímání myokardu z MR obrazů.
2. Nastudování MOLLI MR sekvencí.
3. Nastudování problematiky registrace medicínských obrazů.
4. Rešerše segmentačních metod pro detekci myokardu z MR obrazů.
5. Design a realizace segmentačního algoritmu pro automatizovanou detekci myokardu na MR.
6. Design a realizace registračního algoritmu pro MOLLI sekvence.
7. Realizace softwarového prostředí pro automatizovanou analýzu myokardu z MOLLI sekvencí.
8. Vyhodnocení výsledků práce.

Seznam doporučené odborné literatury:

- [1] SURI, Jasjit S., David Lynn WILSON a Swamy LAXMINARAYAN, ed. *Handbook of biomedical image analysis*. Volume II, Segmentation Models. New York: Kluwer Academic/Plenum Publishers, c2005. ISBN 0-306-48605-9.
- [2] WEBB, Andrew R. *Introduction to biomedical imaging*. Hoboken: Wiley, c2003. IEEE Press series on biomedical engineering. ISBN 0-471-23766-3.
- [3] GONZALEZ, Rafael C. a Richard E. WOODS. *Digital image processing*. 2nd ed. Upper Saddle River: Prentice Hall, c2002. ISBN 0-201-18075-8.
- [4] MODERSITZKI, Jan. *Numerical methods for image registration*. Oxford: Oxford University Press, 2004. Numerical mathematics and scientific computation. ISBN 0-19-852841-8.
- [5] MODERSITZKI, Jan. *FAIR: flexible algorithms for image registration*. Philadelphia: Society for Industrial and Applied Mathematics, c2009. Fundamentals of algorithms. ISBN 978-0-898716-90-0.


Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **doc. Ing. Martin Augustynek, Ph.D.**

Konzultant diplomové práce: **Ing. Jan Kubiček, Ph.D.**

Datum zadání: 01.09.2019

Datum odevzdání: 30.04.2020



doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry



prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prohlášení studenta

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

V Ostravě dne: 15.05.2020

Prohlašuji

.....

Poděkování

Rád bych vyjádřil poděkování vedoucímu mé bakalářské práce, panu doc. Ing. Martinu Augustynkovi, Ph.D. a konzultantu Ing. Janu Kubíčkovi, Ph.D. za rady, vstřícnost a věcné připomínky při konzultacích, které mi pomohly k získání potřebných informací a podkladů pro vytvoření této diplomové práce.

Abstrakt:

Tato diplomová práce se zabývá návrhem a implementací algoritmu pro segmentaci srdečních struktur z MOLLI sekvencí. Pro tuto segmentaci byla využita metoda aktivních kontur založená na lokální Gaussovske distribuci. Tato metoda byla vybrána na základě studia vědeckých prací obsažených v teoretické části. Díky této segmentaci je možné na výsledném binárním modelu měřit parametry srdeční struktury. Dále teoretická část obsahuje poznatky o snímání srdce pomocí MRI a MOLLI sekvencí. Praktická část popisuje jednotlivé kroky předzpracování, segmentace a měření parametrů dané struktury. Měřenými parametry jsou délka, šířka, obsah v řezu a tloušťka srdeční svaloviny levé komory. Závěrem této práce je návrh graficko-uživatelského rozhraní, které umožňuje jednoduchou a intuitivní segmentaci. Součástí diplomové práce je i testování robustnosti segmentace porovnáním výsledků segmentace s manuálními konturami vytvořenými expertem. Na základě testování podobnosti s manuálními konturami pomocí DICE koeficientu, střední kvadratické chyby a koeficientu korelace bylo provedeno vyhodnocení robustnosti a úspěšnosti segmentace.

Klíčová slova: MRI, MOLLI sekvence, segmentace obrazu, aktivní kontury, zpracování obrazu, DICE, korelační koeficient, MSE, střední kvadratická chyba, GUI

Abstract:

This diploma thesis deals with design and implementation of algorithm for segmentation of heart structures from MOLLI sequences. The active contour method based on the local Gaussian distribution was used for this segmentation. This method was chosen based on the study of scientific papers contained in the theoretical part. Thanks to this segmentation, it is possible to measure the cardiac structure parameters in the resulting binary model. Furthermore, the theoretical part contains knowledge about heart sensing using MRI and MOLLI sequences. The practical part describes the individual steps of preprocessing, segmentation and measurement of parameters of the given structure. The measured parameters are length, width, cavity content in the incision and thickness of the left ventricular heart muscle. The conclusion of this work is design of graphical user interface, which allows simple and intuitive segmentation. Part of the thesis is also testing segmentation robustness by comparing segmentation results with manual contours created by an expert. Based on testing of similarity to manual contours using DICE coefficient, mean quadratic error and correlation coefficient, robustness and success of segmentation were evaluated.

Keywords: MRI, MOLLI sequence, image segmentation, active contours, image processing, DICE, correlation coefficient, MSE, mean square error, GUI

Obsah

Seznam obrázků	9
Seznam tabulek	12
Úvod	13
1. Klinické zobrazování magnetické rezonance (MR) srdce.....	14
1.1 Modified look-locker inversion (MOLLI)	18
1.2 Segmentace medicínských obrazů	19
1.2.1 Segmentace srdečních dutin.....	25
1.3 Registrace obrazu	26
1.3.1 Kroky registrace obrazu.....	27
1.3.2 Metody registrace obrazu	28
1.3.3 Odhad transformačního modelu.....	30
2. Studie metod používaných pro segmentaci srdečních struktur	32
2.1 Porovnání segmentačních metod pro MRI měření srdeční funkce u potkanů	32
2.2 Posouzení pohybu stěny MRI levé komory pomocí výpočtu obrazu amplitudy monogenního signálu	36
2.3 Vyhodnocení poloautomatické metody segmentace pravé komory na MR snímcích s krátkou osou.....	41
2.4 Plně automatická segmentace 4D MRI pro funkční měření srdce	45
2.5 Segmentace myokardu z DE MRI s náhodnými cestami a rozptýleným zobrazením tvaru ..	48
2.6 Bezsegmentační objemová metoda pro rychlou vizualizaci smykového napětí cévní stěny pomocí 4D průtokového MRI	51
2.7 Metoda dvoufázové aktivní kontury pro poloautomatickou segmentaci srdce a cév z MRI snímků pro 3D vizualizaci.....	53
2.8 3D metoda lokálního aktivního obrysu založená na 3D Hermite s eliptickými omezeními tvaru pro segmentaci srdečních MR a CT objemů.....	56
2.9 Nepodřízená segmentace myokardu pro srdeční BOLD	60
3. Struktura obrazových dat.....	64
3.1 Selhání srdce s infarktem a bez infarktu	64
3.2 Hypertrofie	66
4. Návrh matematického modelu pro detekci a analýzu myokardu na MR snímcích	68
4.1 Načtení dat	69
4.2 Předzpracování	69
5. Návrh a implementace algoritmu pro detekci srdečních struktur	72

5.1	Metoda založena na lokální Gaussovske distribuci[23]	72
5.2	Segmentace srdečních struktur	75
5.3	Binarizace a registrace obrazu	76
5.4	Měření parametrů srdce	78
5.4.1	Výsledky měření srdečních parametrů	79
5.5	Evaluace přesnosti segmentace	84
5.5.1	DICE koeficient	84
5.5.2	Střední kvadratická chyba (MSE)	85
5.5.3	Index korelace	85
5.5.4	Výsledky porovnání s manuálními konturami	85
5.6	Výpočetní náročnost	87
6.	Graficko-uživatelské rozhraní (GUI)	88
7.	Závěr	96
8.	Zdroje	97
	Seznam příloh	100

Seznam obrázků

Obrázek č. 1 Snímky s nízkým rozlišením pro lokalizaci srdce. (a) axiální rovina, (b) koronární rovina, (c) sagitální rovina.....	15
Obrázek č. 2 Snímek axiální roviny se sekvencí černé krve zobrazující rozdělení plicní tepny a stoupající sestupnou a vzestupnou aortu.....	15
Obrázek č. 3 Systola a diastola z dvoukomorového pohledu (a), čtyřkomorového pohledu (b), pohled výtokového traktu LV (c), pohled krátké osy (d), všechny snímky jsou získány se sekvence "bílé krve"	16
Obrázek č. 4 Zobrazování po podání gadolinia. a) „časný“ snímek gadolinia, který demonstuje trombus levé komory. (b) „Pozdní“ gadoliniový snímek – doba inverze je zvolena tak, aby se vynuloval normální myokard (který je černý), takže jizva obsahující gadolinium byla jasně bílá	17
Obrázek č. 5 Spin-echo sekvence	17
Obrázek č. 6 Gradient echo sekvence.....	18
Obrázek č. 7 Inverzní obnovovací pulz a Saturační pulz.....	18
Obrázek č. 8 Příklad snímání MOLLI sekvence. Srdeční frekvence 80bpm. Modrá čára ukazuje vývoj podélné magnetizace v průběhu akvizice, za předpokladu T1 1100 ms (např. Myokard). Šedá čára ukazuje podélnou magnetizaci pro předpokládaný T1 1600 ms (např. Krev). Červené obdélníky překrývající se na signálových křivkách označují časy, kdy se snímky získávají v režimu jednoho záběru (100 ms) s precesí v ustáleném stavu (SSFP). Během prvního cyklu Look-Locker má první hodnota TI nejkratší hodnotu 100 ms, která je v tomto případě zvýšena o 80 ms pro další LL cykly. Po prvním cyklu LL je sekvence pozastavena na 2 další srdeční cykly, aby se umožnilo plné a nerušené zotavení signálu, než se použije další inverzní impuls.	19
Obrázek č. 9 Příklad segmentace pomocí regionů.....	20
Obrázek č. 10 Rozdělení obrazu na regiony pomocí techniky rozdělení a sloučení [4].....	21
Obrázek č. 11 Histogram jednotlivých snímků rozdělený na jednotlivé shluky, vertikální čára označuje prah rozdělení [19].....	22
Obrázek č. 12 Gaussovske smíšené modely, Černá, červená a zelená křivka představuje Gaussovske rozdělení jednotlivých klastrů. Modrá přerušovaná křivka je jejich součet	23
Obrázek č. 13 Příklad segmentace pomocí shlukování.....	24
Obrázek č. 14 Segmentace aorty pomocí Aktivních kontur s rozdílným počtem iterací.....	25
Obrázek č. 15 Segmentace levé síně. Hrudní aorta je značená zeleně a počáteční bod vyznačen červeně. Žlutá kontura značí srdce	26
Obrázek č. 16 Stručný princip transformace snímku kolene, konkrétně natočení o 45°	28
Obrázek č. 17 Příklad afinních transformací. Translace, rotace, měřítko a střih.....	31
Obrázek č. 18 Segmentační metody, Reprezentativní ilustrace ukazující různé metody segmentace s odpovídajícím vymezením	34
Obrázek č. 19 Koncové diastolické (a,d,g) a Koncové systolické (b, e, h) CMRI snímky levé komory tří pacientů. Snímky c, f a i zobrazují amplitudu získanou pomocí monogenního signálu [10]	40
Obrázek č. 20 Dvoukomorové snímky krátké osy automatické segmentace pravé komory na konci diastolické (levý sloupec) a systolické fáze (pravý sloupec). Bazální řezy, uprostřed dutiny a apikální řezy (obrázky nahoře, uprostřed a dolní řádky). Plné modré a přerušované červené čáry představují obrysy epikardu levé komory a kontury endokardu. Čárkované zelené čáry představují kontury endokardu pravé komory. [11]	44
Obrázek č. 21 Diagram předzpracování obrazu.....	45

Obrázek č. 22 Segmentace LV endokardu (zelená), LV epikardu (červená) a RV (modrá) na numerických snímcích fantomu pomocí LSSPM, na konci diastoly (a, c) a na konci systoly (b, d). Byly testovány dva SNR (a, b: 50; c, d: 25).....	48
Obrázek č. 23 Schematický diagram segmentace LV: LGD byl použit pro získání LV endokardu a LSSPM byl použit pro získání LV epikardu. [12]	48
Obrázek č. 24 Automatická a manuální segmentace tří subjektů.....	50
Obrázek č. 25 Algoritmus pro určování a vizualizaci WSS.....	52
Obrázek č. 26 MRA (A); 4D FlowMRI vizualizace, jednotky cm / s (B); vizualizace WSS, jednotky cPa, jednotlivé ROI jsou barevně označeny a vypočteny (C); kvantifikace WSS pro každou ROI (bílé obrysy) (D). (C): (1) distální sestupná hrudní aorta, (2) celiakální tepna, (3) intrarenální břišní aorta.[18].....	53
Obrázek č. 27 Počet bodů (vrcholů) v po sobě jdoucích iteracích balloon algoritmu	55
Obrázek č. 28 Počet bodů (vrcholů) v procesu segmentace papilárních svalů.....	55
Obrázek č. 29 rozdíl snímku levé komory s konturou tvořící smyčky (vlevo) a po použité anti-smyčková funkce.....	55
Obrázek č. 30 Koeficienty 3D HT aplikované na srdeční objem MR. Řezy ukazují střed srdce. (a) kartézské koeficienty. (b) řízené koeficienty.	58
Obrázek č. 31 Výsledky pro LV, základna (levý sloupec), střed (prostřední sloupec), vrchol (pravý sloupec) [15]	59
Obrázek č. 32 Extrakce pozadí a regionů myokardu. LV krevní pool (vlevo); Transformace vzdálenosti od hranice krevního poolu LV (uprostřed); Základní třídy a popřední třídy (vpravo).	61
Obrázek č. 33 Výsledek segmentace (červený) navrhované metody jak pro CP-BOLD MR, tak pro standardní CMRI ve základní stavu a ischemii pro koncovou diastolickou (ED) a koncovou systolickou (ES) fázi překrývající se s odpovídajícími konturami ruční segmentace (zelené), které určili odborníci	63
Obrázek č. 34 Ukázka MOLLI sekvence pacienta po selhání srdce s infarktem	65
Obrázek č. 35 Ukázka MOLLI sekvence pacienta po selhání srdce bez infarktu	66
Obrázek č. 36 Ukázka MOLLI sekvence pacienta s hypertrofií	67
Obrázek č. 37 Zobrazení srdce z pohledu krátké osy, RV – Right Ventricle (pravá komora), LV - left Ventricle (Levá komora) [21].....	68
Obrázek č. 38 Vývojový diagram segmentace myokardu	69
Obrázek č. 39 Graf jasové transformace u segmentace LV svaloviny	70
Obrázek č. 40 Ukázka předpracování obrazu pro segmentaci LV: zleva doprava – načtený snímek, ROI, snímek po aplikaci jasové transformace, snímek po aplikaci mediánového filtru. Nahoře pacient po selhání srdce s infarktem, dole pacient s hypertrofií.....	70
Obrázek č. 41 výsledek předzpracování pro segmentaci srdeční svaloviny. Nahoře pacient po selhání srdce s infarktem, dole pacient s hypertrofií.....	71
Obrázek č. 42 Evaluační kontury postupně od shora dolů: Inicializační kontura, segmentace po 50 iteracích, 150 iteracích, 250 iteracích	76
Obrázek č. 43 Ukázka energetické mapy aktivní kontury segmentované levé srdeční komory	77
Obrázek č. 44 Princip nalezení těžiště hledané struktury	77
Obrázek č. 45 Příklad binarizovaných snímků, konkrétně pro pacienta trpícího hypertrofií	78
Obrázek č. 46 Zprůměrovaný snímek z předchozích binarizovaných snímků.....	78
Obrázek č. 47 Zobrazení snímku v programu MicroDicom	79
Obrázek č. 48 Boxplot délky segmentované srdeční struktury napříč skupinami	82
Obrázek č. 49 Boxplot šířky segmentované srdeční struktury napříč skupinami.....	82

Obrázek č. 50 Boxplot obsahu segmentované srdeční struktury napříč skupinami	83
Obrázek č. 51 Boxplot tloušťky srdeční svaloviny napříč skupinami.....	83
Obrázek č. 52 Kontury získané pomocí segmentace (vlevo), vytvořené manuálně expertem	84
Obrázek č. 53 Diagram funkce GUI.....	88
Obrázek č. 54 Graficko-uživatelské rozhraní	88
Obrázek č. 55 Zobrazení prvního snímku sekvence po jejím načtení.	89
Obrázek č. 56 Rozhraní s vybraným ROI.....	90
Obrázek č. 57 Výsledný obraz po předzpracování	90
Obrázek č. 58 Rozhraní s vloženou počáteční konturou o velikosti 10	91
Obrázek č. 59 Rozhraní po provedení segmentace	92
Obrázek č. 60 Zápis parametrů dutiny LV do tabulky.....	92
Obrázek č. 61 Předpracování a iniciační kontura při segmentaci srdeční svaloviny	93
Obrázek č. 62 Výsledek segmentace srdeční svaloviny.....	93
Obrázek č. 63 Výsledek srdeční svaloviny po binarizaci a odečtení segmentované dutiny.	94
Obrázek č. 64 Výsledná tabulka měřených parametrů	94
Obrázek č. 65 Příklad výsledných uložených snímků segmentované srdeční struktury, vlevo dutina LV, vpravo svalovina LV	95
Obrázek č. 66 Příklad uložené tabulky měřených parametrů v soboru .xlsx	95
Obrázek č. 67 Příklad části uložených souřadnic kontury dutiny LV	95
Obrázek č. 68 Výsledky pro pacienti po selhání srdce s infarktem. Sestupně pacient 1-5	101
Obrázek č. 69 Výsledky pro pacienty po selhání srdce bez infarktem. Sestupně pacient 13-17	102
Obrázek č. 70 Výsledky pro pacienty trpící hypertrofií. Sestupně pacient 25-29	103
Obrázek č. 71 Výsledky pro pacienty se zdravým srdcem. Sestupně pacient 37-41.....	104

Seznam tabulek:

Tabulka 1 Souhrn srdečních parametrů	35
Tabulka 2 Porovnání poloautomatické segmentační metody s manuální segmentací	35
Tabulka 3 Hlavní charakteristiky studované populace, děleno na základě normální a abnormální LV	39
Tabulka 4 Výsledky citlivosti, specifity a přesnosti interpretace pohybu stěny bez as parametrickým obrazem amplitudy na základě monogenního signálu	39
Tabulka 5 Přehled měření a analýz	42
Tabulka 6 Charakteristiky studie a základní měření pravé komory	43
Tabulka 7 Vliv výběru tvarových šablon vyhodnocených pomocí DSC (%)	51
Tabulka 8 Parametry získávání 4D toku obrazu a faktory zrychlení pro pseudonáhodné podvzorkování s proměnnou hustotou	52
Tabulka 9 DSC získané segmentací výsledků 4 metod, včetně navržené metody. Testování proběhlo na MR datasetu 1	59
Tabulka 10 Průměrné PCD a MHD [mm]	59
Tabulka 11 Parametry aktivních kontur	75
Tabulka 12 Měření parametry u pacientů se selháním srdce s infarktem	79
Tabulka 13 Statistické vlastnosti pro měření parametry u pacientů se selháním srdce s infarktem	80
Tabulka 14 Měření parametry u pacientů se selháním srdce bez infarktu	80
Tabulka 15 Statistické vlastnosti pro měření parametry u pacientů se selháním srdce bez infarktu	80
Tabulka 16 Měření parametry u pacientů s hypertrofií srdce	81
Tabulka 17 Statistické vlastnosti pro měření parametry u pacientů s hypertrofií srdce	81
Tabulka 18 Měření parametry pacientu se zdravým srdcem	81
Tabulka 19 Statistické vlastnosti pro měření parametry u pacientů se zdravým srdcem	82
Tabulka 20 Výsledky porovnání segmentovaných struktur s manuálními konturami	85
Tabulka 21 Výsledné měření parametry pro pacienty po selhání srdce s infarktem	105
Tabulka 22 Výsledné měření parametry pro pacienty po selhání srdce bez infarktu	105
Tabulka 23 Výsledné měření parametry pro pacienty s hypertrofií	106
Tabulka 24 Výsledné měření parametry pro pacienty se zdravým srdcem	106

Úvod

V této diplomové práci bylo úkolem navrhnout automatickou analýzu a modelování myokardu z MOLLI sekvencí za pomoci prostředí MATLAB. Parametry levé komory jako objem a tloušťka srdeční svaloviny, mohou indikovat k vážným poruchám myokardu. Proto se tato diplomová práce zabývá detekcí a měřením parametrů levé komory.

Na základě teoretické části informující o způsobech snímání srdce, získání MOLLI sekvencí a metodách používaných pro extrakci srdečních struktur, bude navržen a testován segmentační algoritmus. V praktické část popisuje počáteční úpravu dat jako výběr oblasti zájmu a předzpracování formou jasových transformací a filtrací. Tímto dojde k dostatečnému zvýraznění hledaných struktur pro segmentaci. Segmentační algoritmus je potřeba správně nastavit tak aby docházelo k co nejmenším chybám. Následně bude algoritmus aplikován a data obsahující 45 pacientů. Následně byla testována robustnost algoritmu při porovnání s manuálními konturami obsaženými v datové sadě.

Závěrem diplomové práce bude navrhnout graficko-uživatelské rozhraní po automatizovanou segmentaci a měření srdečních parametrů. Výsledky byly zaznamenány dále v této diplomové práci.

1. Klinické zobrazování magnetické rezonance (MR) srdce

Magnetická rezonance je zobrazovací metoda, která využívá silných elektromagnetů, řádově o síle několik Tesla (T), a rádiových vln pro zobrazení daných struktur. V případě srdce poskytuje detailní snímky tohoto orgánu a cév z mnoha pohledů, včetně 3D rekonstrukce.

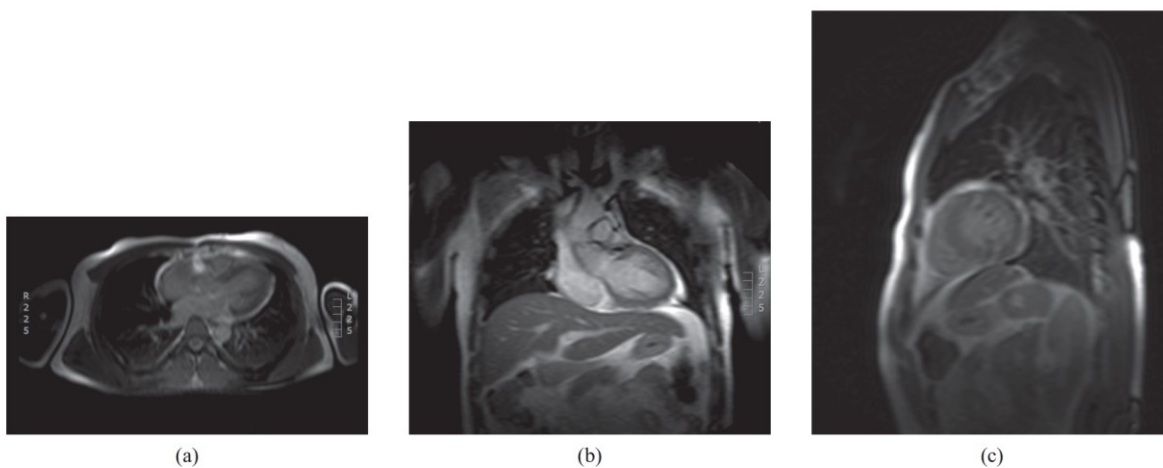
Vyšetření MR srdce indikuje kardiolog, kardiochirurg nebo lékař s atestací z oboru vnitřního lékařství po konzultaci s kardiologem. Mezi indikace k zobrazování MR srdce patří:

- Ischemická choroba srdeční:
 - Akutní forma
 - Chronická forma
- Kardiomyopatie
 - Hypertrofická kardiomyopatie – zbytnění srdeční svaloviny bez dilatace levé komory (dále jen LK)
 - Dilatační kardiomyopatie – dilatace komor a snížení jejich kontraktility
 - Arytmogenní kardiomyopatie – náhrada myokardu tukovou a fibrózní tkání
 - Sarkoidóza – granulomatózní onemocnění neznámé příčiny
 - Hemochromatóza – nadměrné ukládání železa do buněk
 - Akutní myokarditida
 - Specifické kardiomyopatie – amyloidóza, Fabryho choroba, endomyokardiální fibróza, suspekce na kardiotoxické poškození myokardu po chemoterapii atd.
- Vrozené srdeční vady
- Vady chlopní
- Angiografie
- Patologické srdeční útvary
- Onemocnění perikardu
- Arytmologické indikace

V současné době je většina srdeční MRI prováděna při 1,5 T, někdy se používá i vyšších hodnot (3 T), které mohou zlepšit zobrazování v důsledku lepšího poměru signál-šum. Rutinní vyšetření srdeční MRI začíná sadou obrázků s nízkým rozlišením (viz Obrázek č. 1), a to z důvodu lokalizace srdce v hrudníku, aby bylo umožněno další plánování diagnostických obrazů. Anatomická informace se získá ze statických snímků. Tyto snímky lze získat se sekvencí tzv. „černé krve“ nebo „bíle krve“ viz Obrázek č. 2 a Obrázek č. 3 (pojmy budou vysvětleny dále v článku) a mohou být pořízeny i v koronární a sagitální orientaci. Základní snímky srdce jsou pořízeny ze standardních echokardiografických pohledů [2]:

- Vertikální pohled dlouhé osy
- Horizontální pohled dlouhé osy
- Pohled krátké osy
- Čtyřkomorový pohled
- Dvoukomorový pohled
- 3-komorový pohled s levou komorou
- Pohled výtokového traktu levé komory
- Pohled krátké osy pravé komory
- Pohled výtokového traktu pravé komory [3]

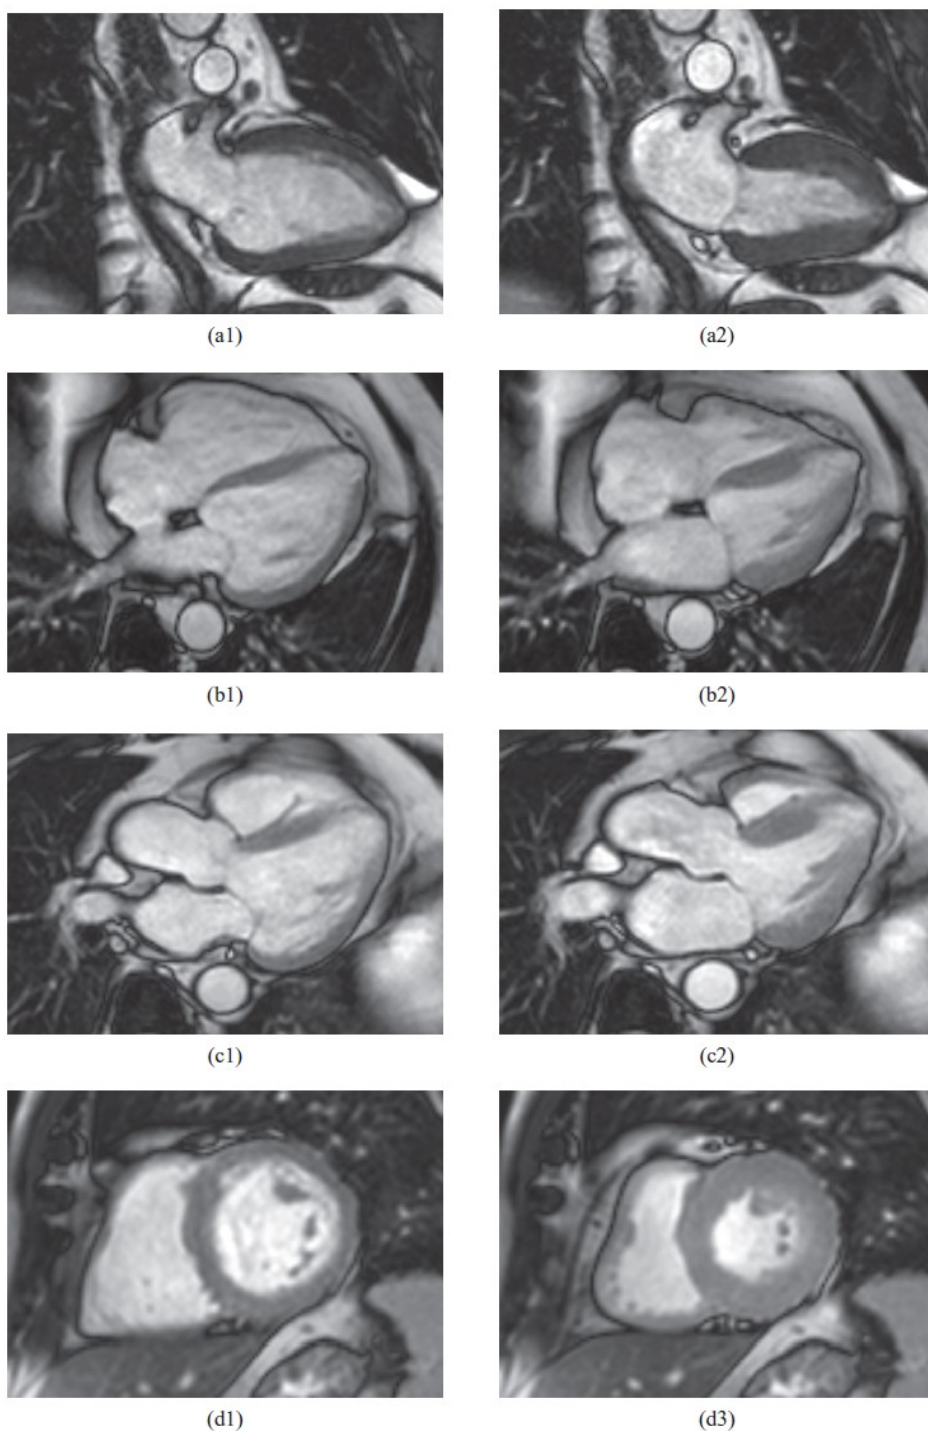
Příklady některých pohledů lze vidět na Obrázek č. 3. Pomocí snímků z těchto pohledů lze vypočítat komorové objemy, ejekční frakci a množství srdeční svaloviny [2].



Obrázek č. 1 Snímky s nízkým rozlišením pro lokalizaci srdce. (a) axiální rovina, (b) koronární rovina, (c) sagitální rovina



Obrázek č. 2 Snímek axiální roviny se sekvencí černé krve zobrazující rozdělení plicní tepny a stoupající sestupnou a vzestupnou aortu




Obrázek č. 3 Systola a diastola z dvoukomorového pohledu (a), čtyřkomorového pohledu (b), pohled výtokového traktu LV (c), pohled krátké osy (d), všechny snímky jsou získány se sekvence "bíle krve"

Za standardní součást MR srdce jsou považovány dynamické (cine) sekvence, statické předkontrastní (T1 a T2 vážené zobrazení) a postkontrastní sekvenky (T1 vážené pozdní postkontrastní skeny – late gadolinium enhancement – LGE), případně průtoková měření [1]. Sekvenky "bílé a černé krve" jsou dány relaxačním časem. U váženého zobrazení T1 je relaxační čas kratší a tím je vyšší intenzita signálu pro tuk, a proto se na snímcích jeví jako bílý kdežto tekutina jako černá. U váženého

zobrazení T2 je relaxační čas delší a je vyšší intenzita signálu pro tekutiny, a tedy se tekutiny zobrazí jako bílá.


Kontrast gadolinia lze použít mnoha způsoby k získání dalších informací. Zobrazování prvního průchodu může být použito k hodnocení perfuze a může být kombinováno s adenosinovým stresem pro zkoumání indukovatelných defektů perfuze. Gadolinem vylepšená angiografie MR může poskytnout užitečné 3D obrazy struktur, jako je aorta. Nejčastěji se gadolinium používá v srdeční MRI spolu s inverzní obnovovací sekvencí k získání kontrastních snímků „časných“ (snímky pořízené bezprostředně po injekci gadolinia) nebo „pozdní“ (snímky získané přibližně 10 minut po injekci). Při získávání IR akvizice se gadolinium v krevním poolu výrazně kontrastuje s vaskulárním trombem, který se na „časných“ gadoliniových snímcích objevuje jako černý „defekt výplně“ (Obrázek č. 4a). Gadolinium se vstřebává do normálních buněk, ale pak se aktivně vylučuje. Mezitím se gadolinium hromadí v extracelulárním prostoru, například v oblastech jizvy nebo fibrózy. Na „pozdních“ gadoliniových snímcích se normální myokard zdá „nulovaný“ (černý), zatímco oblasti obsahující gadolinium jsou jasně bílé (Obrázek č. 4b).



Obrázek č. 4 Zobrazování po podání gadolinia. a) „časný“ snímek gadolinia, který demonstruje trombus levé komory. (b) „Pozdní“ gadoliniový snímek – doba inverze je zvolena tak, aby se vynuloval normální myokard (který je černý), takže jizva obsahující gadolinium byla jasně bílá


Pro snímání srdce pomocí MR se využívají následující sekvence:

- I. Spin-echo sekvence, která využívá 90° excitační pulz a 180° refokusační pulz. Využívá se převážně pro zobrazení morfologie, anatomie, nádorů atd.



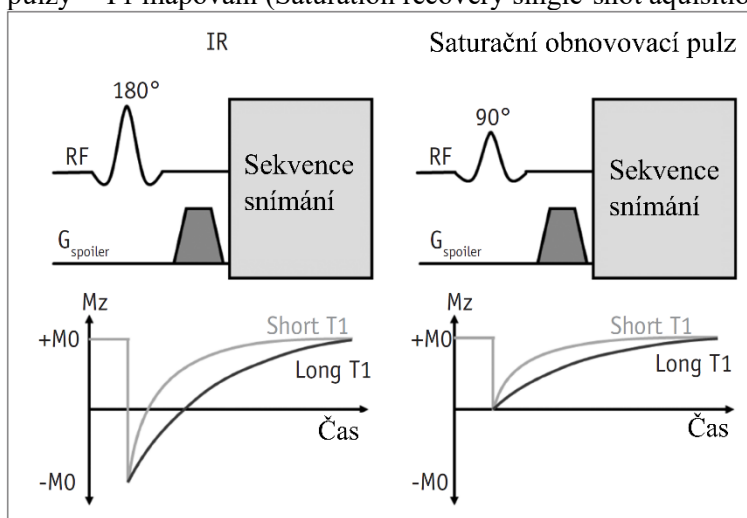
Obrázek č. 5 Spin-echo sekvence

- II. Gradient-echo sekvence, který využívá nízké úhly převrácení a gradientní pulzy pro zobrazení cine, perfuze, late gadolinium enhancement (LGE)



Obrázek č. 6 Gradient echo sekvence

- III. Inversion recovery (IR) – LGE, T1 mapování (Modified Look–Locker Inversion, MOLLI)
 IV. Saturační pulzy – T1 mapování (Saturation recovery single-shot aquisition, SASHA)

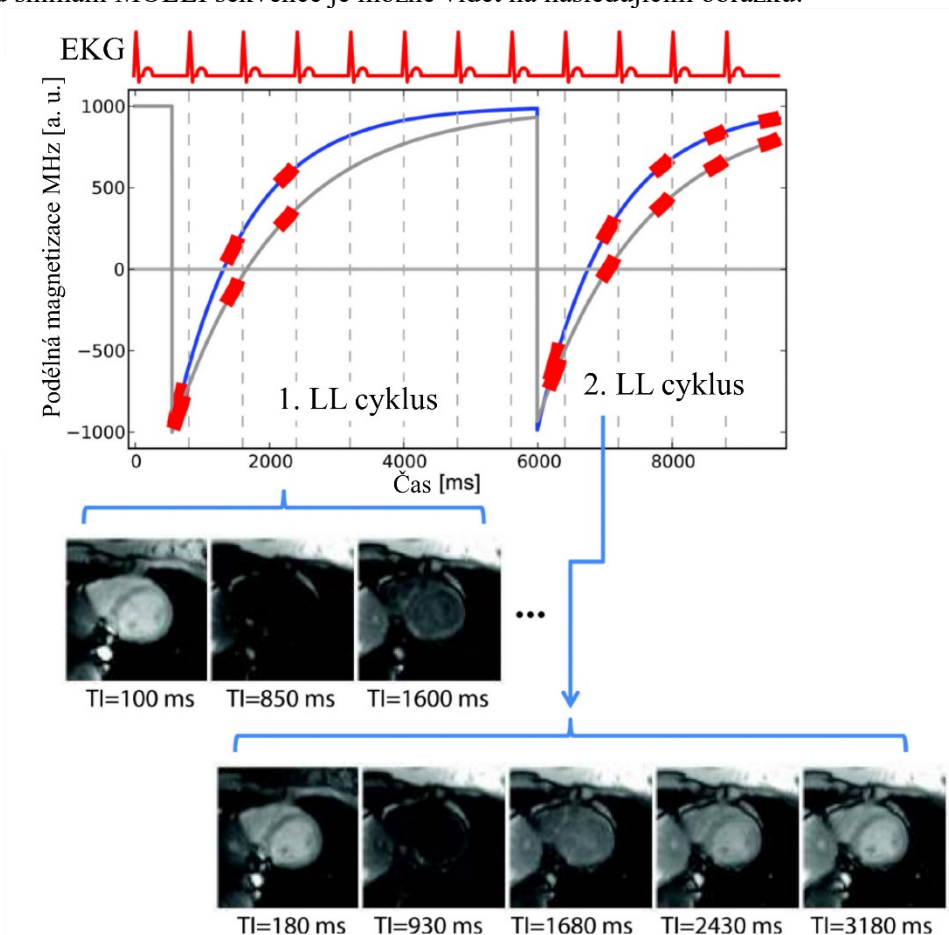


Obrázek č. 7 Inverzní obnovovací pulz a Saturační pulz

1.1 Modified look-locker inversion (MOLLI)

MOLLI sekvence se skládá z několika tzv. “Look-Locker“ sad z nichž každá obsahuje několik snímků spouštěných na základě EKG ve stejné srdeční fázi. Každý cyklus Look-Locker začíná inverzním pulzem, následovaným rychlým získáním jednorázových snímků s precesí v ustáleném stavu. Snímky se získávají v pevném, uživatelem definovaném bodě srdečního cyklu, obvykle diastole. Pro následující cykly Look-Locker je inverzní impuls posunut v rámci srdečního cyklu o ~ 50 -300 ms. Každý cyklus poskytuje obrazy s TI (Time Inversion – časová inverze) přírůstky odpovídající délce srdečního rytmu, zatímco změna načasování pro inverzní pulz přidává TI časy s menšími přírůstky 100-200 ms, vzhledem k již získaným bodům. Konečným výsledkem je série obrázků s časy TI, které obvykle pokrývají rozsah TI až do 2–5 srdečních tepů. Po prvním cyklu nastává relaxační období trvající čtyři srdeční rytmy, které umožňují úplnou obnovu před aplikací inverzního pulzu pro další cyklus. U MOLLI sekvence se většinou určuje tzv. schéma, které může vypadat takto „5-3-3“. To znamená, že v prvním cyklu se získá 5 snímků

a v druhém a třetím cyklu se získají snímky 3. Pro příklad: pokud je srdeční frekvence pacienta 60 bpm a TI posun mezi LL cykly 150 ms, pak by bylo možné získat přibližně následujících 10 TI časů, uvedených v tomto pořadí pořízení: 100, 1100, 2100, 3800, 4800 200, 1200, 2200, 300, 1300, 2300 ms. [17] Příklad snímání MOLLI sekvence je možné vidět na následujícím obrázku:



Obrázek č. 8 Příklad snímání MOLLI sekvence. Srdeční frekvence 80bpm. Modrá čára ukazuje vývoj podélné magnetizace v průběhu akvizice, za předpokladu T_1 1100 ms (např. Myokard). Šedá čára ukazuje podélnou magnetizaci pro předpokládaný T_1 1600 ms (např. Krev). Červené obdélníky překrývající se na signálových křivkách označují časy, kdy se snímky získávají v režimu jednoho záběru (100 ms) s precesí v ustáleném stavu (SSFP). Během prvního cyklu Look-Locker má první hodnota TI nejkratší hodnotu 100 ms, která je v tomto případě zvýšena o 80 ms pro další LL cykly. Po prvním cyklu LL je sekvence pozastavena na 2 další srdeční cykly, aby se umožnilo plné a nerušené zotavení signálu, než se použije další inverzní impuls.


1.2 Segmentace medicínských obrazů

Segmentace obrazu se týká procesu rozdělení digitálního obrazu na více segmentů, tj. množiny pixelů, které mají určitou podobnost dle některých kritérií homogenity, jako je barva, intenzita nebo textura. Jedná se o jeden z nejdůležitějších kroků zpracování obrazu a může sloužit k detekci a identifikaci objektů nebo hran v obraze případně pro 3D modelování. Bylo navrženo několik segmentačních metod a ty základní budou uvedeny dále:

- (1) Segmentace podle regionů


Základní myšlenka nejprve spočívá ve výběru počátečního bodu, sousední pixely se s tímto bodem spojí, pokud splňují kritérium jednotnosti. Například v RGB obrázku lze jako kritérium mezi sousedními pixely použít euklidovskou vzdálenost v prostoru RGB.

Této metodě se říká růst regionu. Pokaždé když je pixel přidán k regionu dojde k aktualizaci středních hodnot regionu s ohledem na nově přidáný bod. Princip algoritmu lze popsat takto: (I) začíná se s počátečním pixelem(seed pixel), (II) pomocí 8-conectivity modelu se vypočítá míra jednotnosti každého sousedního pixelu s počátečním bodem, (III) je-li splněna míra jednotnosti pixel se přidá do regionu, (IV) dojde k označení přidáného pixelu danou barvou určenou pro region a aktualizuje se statistika regionu s ohledem na nově přidáný bod, (V) pokud dojde k zastavení růstu regionu, způsobenému negativním výsledkem míry jednotnosti, vybere se další dostupný neznačený bod a provede se celá operace znovu. Na závěr je nutná filtrace, nejčastěji pomocí mediánového filtru. Tímto bude zajištěno, že malé regiony, řádově o velikosti jednotek pixelů, budou přiřazeny k větším okolním regionům. Výstup segmentace je prezentován na Obrázek č. 9:



Obrázek č. 9 Příklad segmentace pomocí regionů

Technika rozdělení a sloučení: tuto techniku lze chápat jako zobecnění růstu regionů. Nejprve dojde k rozdělení obrazu na malé regiony, tyto regiony následně slučují do větších oblastí, které splňují podmínky segmentace. Celkový postup lze popsat takto: (I) Jakákoliv oblast, pro kterou neplatí podmínky jednotnosti se rozdělí na čtyři části, (II) Pokud již není možné části rozdělit dojde k slučování regionů pro které platí míra jednotnosti, (III) pokud již není možné sloučení dalších regionů dojde k zastavení procesu, (IV) každý region se označí jinou barvou pro lepší rozlišitelnost.

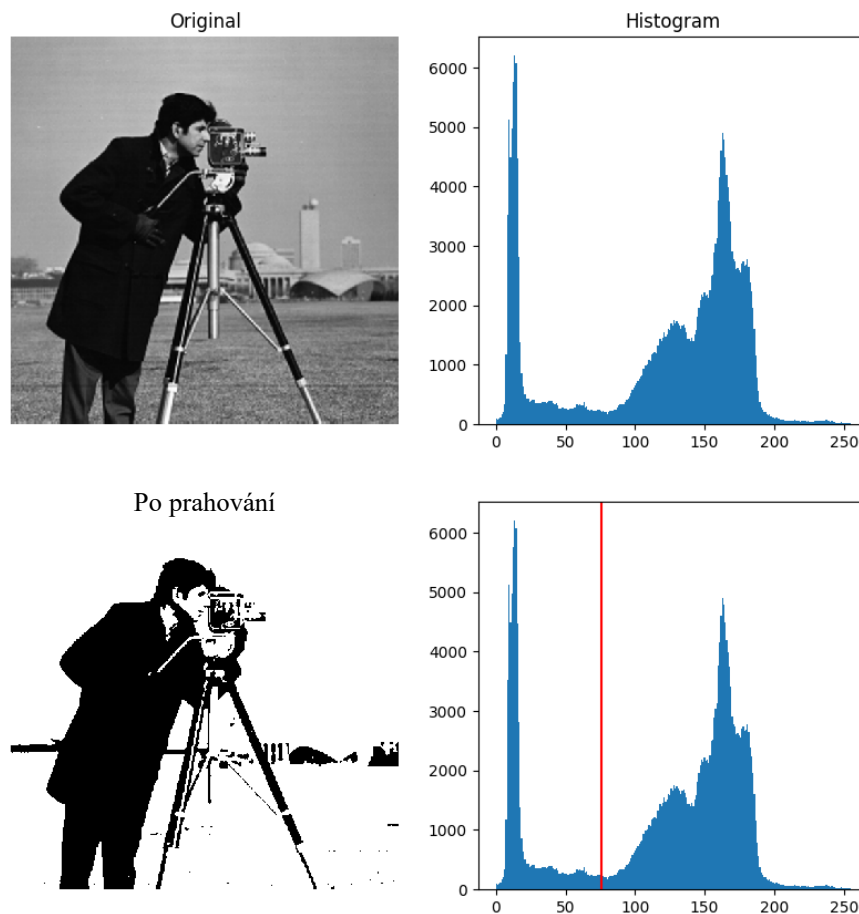


Obrázek č. 10 Rozdělení obrazu na regiony pomocí techniky rozdělení a sloučení [4]

(2) Techniky shlukování


Techniky založené na shlukování (klastrování) fungují na principu seskupení pixelů na základě míry podobnosti, bez ohledů na prostorový vztah (vztah okolí). Příkladem může být prahování kdy dojde k binarizaci snímku na základě dané hodnoty neboli prahu. Tedy pixely s hodnotami pod tímto prahem jsou přiřazeny do jedné skupiny a pixely s hodnotou větší, než tento práh jsou přiřazeny do skupiny druhé. Mezi hlavní metody patří:

a) Histogramové prahování: histogram je konstruován na prostoru prvků, kde je třeba provést segmentaci. Daný prostor prvků může být jednoduchá jako hodnoty šedi, ale i složitější více dimenzionální obraz. Poté jsou prahové hodnoty automaticky nastaveny na nejnižší hodnoty, která se vyskytují podél histogramu




Obrázek č. 11 Histogram jednotlivých snímků rozdělený na jednotlivé shluky, vertikální čára označuje prah rozdělení [19]

b) Gausovské smíšené modely (GMM): Tato metoda vychází také z histogramu. Ovšem tentokrát se k prahování používá množství Gaussovských distribucí. Konkrétně se jedná o součet Gaussovských hustot. Jakmile jsou GMM stanoveny provede se segmentace. Problém ovšem nastává v tom, že je nutno použít předem danou hodnotu pro počet klastrů nebo využít program který tuto hodnotu vypočte.



Obrázek č. 12 Gaussovské smíšené modely, Černá, červená a zelená křivka představuje Gaussovské rozdělení jednotlivých klastrů. Modrá přerušovaná křivka je jejich součet

c) K-means klastrování: Jedná se o iterační algoritmus, který rozděluje obrazové pixely do K odlišných tříd pomocí K prahových hodnot. Prahové hodnoty jsou stanoveny tak, aby se minimalizoval celkový rozptyl uvnitř třídy. Algoritmus lze popsat takto: (I) Náhodné určení K prahů, (II) segmentace s ohledem na dané prahy, (III) vypočítání středu pro každý klastr, (IV) vypočítání průměrné hodnoty pixelů pro každý klastr, (V) nastavení nových hodnot středů klastrů na základě vypočítaných průměrů, (VI) nastavení nových prahových hodnot tak aby byly uprostřed mezi klastrovými centry a segmentovat obraz, (VII) následná iterace, dokud nedojde k zastavení pohybu středů klastrů. Ovšem je zde stejný problém jako u GMM, a to že počet klastrů se volí náhodně nebo na základě dalšího programu.



Obrázek č. 13 Příklad segmentace pomocí shlukování

(3) Segmentace založená na hranách

Principem této metody je rozdělení obrazu na segmenty na základě jejich hran. Nejprve je tedy potřeba nalézt hrany v obraze. To lze provést například pomocí Sobelova operátoru nebo „canny edge“ detektoru a dalších. Poté obraz zpracovává obraz hrany tak, aby zůstaly pouze uzavřené hranice objektů. Nakonec jsou výsledky transformovány do obyčejného segmentovaného obrazu vyplněním hranic objektů. Je ovšem nutná filtrace, a to z důvodu odstranění šumu v obraze, který by mohl způsobit velkou nespojitost hran. K propojení hran se využívá Hugova transformace nebo hledání sousedství.

(4) Techniky založené na klasifikátoru

Tato technika je založená na předem vyškoleném klasifikátoru, který následně soužijí k odlišení dané struktury od ostatních. Dnes se pro tento typ segmentace převážně využívají neuronové sítě. Jedná se o velkou množinu propojených elementárních procesorů, které se mohou naučit nelineární vztahy mezi vstupem a výstupem. Pro segmentaci mohou být neuronové sítě trénovány na histogramech vstupních obrazů, případně přímo na jejich pixelech.

(5) Aktivní kontury (AC)

Aktivní konturu lze jednoduše definovat jako křivku, která dokáže měnit svůj tvar na základě vnitřních a vnějších sil, které působí na křivku a určují její deformaci, dokud nesplňuje předdefinované podmínky. Většinou se používá k segmentaci objektu tím, že se nechá přibližovat a usadit k jeho hranicím. Dnes se hojně využívají dvě křivky, balón a had. Balón funguje na principu roztahování kontury do prostoru, dokud nenarazí na hranu objektu, kde se zastaví. Celý proces se zastaví až dojde k vyplnění celého objektu. Had naopak funguje na principu kmitání dané křivky a jejímu následnému zvětšování. Pohyb hada je modelován jako proces minimalizace energie, kde celková energie E , která má být minimalizována, sestává ze tří výrazů: Termín E_i je založen na vnitřních silách hada; zvyšuje se, pokud je had natažený nebo ohnutý. Termín E_e je založen na vnějších silách; snižuje se, pokud se had přiblíží k části obrazu, do které chceme, aby se pohyboval. Poslední termín E_c lze použít k uložení dalších

omezení, jako je penalizace vytváření smyček v křivce hada, penalizace křivek pohybujících se příliš daleko od počáteční polohy nebo penalizace křivek pohybujících se do nežádoucí obrazové oblasti.



Obrázek č. 14 Segmentace aorty pomocí Aktivních kontur s rozdílným počtem iterací

(6) Metody založené na atlasu

Segmentace založená na atlasu zahrnuje sestavení registrovaných a ručně anotovaných segmentačních objektů, kterým se nazývá atlas. Poté pro danou instanci obrazu začíná segmentace nejprve zaregistrováním obrazu vzhledem ke shodě se sadou obrázků v Atlasu. V důsledku toho je segmentační štítek každého pixelu odvozen od odpovídajících štítků v této poloze v obrazových instancích Atlasu. Běžné způsoby, jak odvodit štítek, zahrnují hlasovací schéma nebo vážený hlasovací systém vysvětlený v [6] nebo pravděpodobnostní maximum a posteriori odvození. Segmentace založená na atlasu se ukázala jako velmi užitečná a lepší, pokud existuje výrazná variace uvnitř cílové oblasti, která má být segmentována. [5]

1.2.1 Segmentace srdečních dutin

Zde budou zmíněny segmentační metody používané pro jednotlivé srdeční dutiny.

(1) Levá komora (LV)

Automatická segmentace levé síně je náročný proces z důvodu variace tvaru v řezech a srdečních fázích, překrývání intenzity v srdečních oblastech, nedostatek informací o hranách a variabilita mezi subjekty. Bylo navrženo mnoho metod, které vedou k přesné segmentaci LV a okolních stěnových struktur. Mezi nejpoužívanější metody patří aktivní kontury a segmentaci založenou na atlasu. Tyto metody ovšem používají časově náročné učení modelů a jsou náchylné na variabilitu mezi subjekty. Nicméně představují velice dobré výsledky. Ovšem hlavním problémem je pomalá segmentace. Byly navrženy i metody využívající neuronových sítí, techniky shlukování nebo shlukování pomocí GMM nicméně žádná z těchto metod nevykazovala tak dobré výsledky jako AC a metody založené na atlasu. Byly ovšem navrženy i automatické metody jako třeba Lu a kol. [9], kteří navrhli automatickou metodu segmentace LV pomocí technik základní zpracování obrazu. Kdy se nejprve provede binarizace ROI (Region of interest – oblast zájmu) pomocí Otsu metody. Poté se odstraní objekty menší, než je zvolený počet pixelů a je vypočten konvexní obal pro zbylé objekty. Za LV je pak považován objekt s největší kruhovostí. Ostatní struktury jako kontury endokardu, papilární svaly a další, detekují pomocí řady maskovacích a morfologických operací


(2) Pravá komora (RV)

Problém segmentace RV je obzvláště náročný vzhledem k půlměsíčitému tvaru s vysokou variabilitou, tenkým a často nerozeznatelným stěnám myokardu a nehomogenním a nedefinovaným

hranicím. Algoritmy segmentace RV jsou vzácné a nikdy nebyly vyhodnoceny na základě běžných srovnávacích údajů. Nejúspěšnější přístupy jsou založeny na multiatlasovém segmentačním rámci. Cílový obraz je registrován ke všem obrazům intenzity atlasů, načež jsou značené obrazy z atlasů mapovány zpět na cílový obraz. Poté jsou všechny transformované značené obrazy sloučeny do jediné segmentace pomocí metody fúzní značky. Nedávná studie prokázala zlepšení rychlosti a přesnosti segmentace s využitím kombinace prahování akumulátoru s vymezením okna, binárního rozdílu gaussových filtrů, optimálního prahování a morfologie k řízení segmentace.

(3) Levá síň (LA)

Pro segmentaci LA se nejprve extrahuje celý „krevní pool“ pomocí prahování intenzity a poté se rozdělí do různých srdečních dutin provedením řezů při zúžení. Tento proces ovšem vyžaduje zásah uživatele pro nastavení prahových hodnot z důvodu vysoké variability subjektů a jejich rozdílné distribuce intenzity. Pokud ovšem zúžení není zřetelné pak dojde k neúspěšné segmentaci. Dále metoda prokazuje velkou úspěšnost v případě, že je uživatelem vybrán i počáteční bod segmentace. A následně se využívá růstu regionu pro segmentaci dutiny. Metoda navržená Depa a kol. segmentuje LA pomocí robustní segmentace založené na atlasu. Autoři ve své práci používají 15 ručně segmentovaných a registrovaných šablon jako Atlas. Skutečná segmentace se pak provádí pomocí algoritmu fúzního značení založeného na maximálním zadním odhadu pro každý voxel testovacích obrazů.



Obrázek č. 15 Segmentace levé síně. Hrudní aorta je značená zeleně a počáteční bod vyznačen červeně. Žlutá kontura značí srdce

(4) Pravá síň (RA)

Zde funguje podobný princip jako u segmentace levé síně, a to o segmentaci „krevního poolu“. Nicméně existují jiné metody, Chen et al., kteří využívají pokročilou úroveň segmentace obrazu založená na segmentaci k získání pravé síně. Namísto řízení iterace množiny úrovní pouze pomocí intenzity obrazu a gradientu, zahrnují i model tvaru předem vytvořený pro vedení segmentace. Tvarový model je konstruován pomocí vlastních tvarů určených pomocí analýzy hlavních komponent (PCA) z ručně anotovaných a seřazených tvarů. Během iterace optimalizace sady úrovní se také minimalizuje energie s ohledem na váhy vlastních tvarů. Jejich výsledky prokázaly významné zlepšení oproti variantám, které nezahrnují tvarový model.

1.3 Registrace obrazu

Registrace obrazu je interpretována jako proces překrývání dvou nebo více obrázků stejné scény s ohledem na konkrétní referenční obrázek. Snímky mohou být pořizovány v různých bodech (časových bodech), z různých perspektiv (úhly pohledu) a navíc různými senzory. Je potřeba najít takovou transformaci obrazu, aby podobnost vůči druhému obrazu byla co největší. Cílem je v zásadě detekovat skrytý vztah mezi vstupním a referenčním obrazem, který je obvykle označen maticí transformace souřadnic. V souladu s tím může být registrace obrazu v podstatě navržena jako problém s optimalizací.

Podle způsobu získávání obrázků může být aplikace registrace obrazu rozdělena do následujících skupin:

(1) Analýza více pohledů: Obrázky podobného objektu nebo scény jsou zachyceny z více pohledů, aby se získala lepší reprezentace skenovaného objektu nebo scény. Příklady zahrnují mozaikování obrázků a obnovení tvaru.

(2) Multičasová analýza: Snímky stejného objektu / scény jsou zachyceny v různých časech obvykle za odlišných podmínek, aby bylo možné pozorovat změny v objektu / scéně, které se objevily mezi po sobě jdoucími akvizicemi obrázků. Příklady zahrnují sledování pohybu, sledování růstu nádorů.

(3) Multimodální analýza: Používají se různé snímače k získání obrázků stejného objektu / scény k sloučení informací získaných z různých zdrojů za účelem získání markantů objektu / scény. Příklady zahrnují integraci informací ze senzorů s odlišnými charakteristikami poskytující lepší prostorové a spektrální rozlišení nezávislé na osvětlení - to záleží na robustnosti registračního algoritmu, kombinace senzorů zachycujících anatomické informace, jako je magnetická rezonance (MRI), ultrazvuk nebo CT se senzory získávání funkčních informací, jako je pozitronová emisní tomografie (PET), jednofotonová emisní počítačová tomografie (SPECT) nebo magnetická rezonanční spektroskopie (MRS) ke studiu a analýze poruch záchvatů, Alzheimerovy choroby, deprese a dalších chorob.

1.3.1 Kroky registrace obrazu

(1) Detekce funkcí:

Toto je důležitý úkol procesu registrace snímku. Proces detekce může být manuální nebo automatický v závislosti na složitosti, i když je preferována automatická detekce příznaků. Jako příznaky mohou sloužit uzavřené hraniční oblasti [9-16], hrany, obrysy [17-26], průsečíky linií, rohy [27] spolu s jejich zástupci bodů, jako je těžiště nebo konce čar (souhrnně známé jako kontrolní body. Tyto prvky musí být snadno detekovatelné, to znamená, že tyto vlastnosti budou fyzicky interpretovatelné a identifikovatelné.

(2) Shoda příznaků:

Tento krok v podstatě stanoví shodu mezi vlastnostmi detekovanými v snímaném snímku a těmi detekovanými ve snímku referenčním [28-36]. K nastavení přesné shody jsou použity různé deskriptory prvků a míry podobnosti. Deskriptory příznaků musí být formulovány tak, aby zůstaly nezměněny navzdory jakýmkoli degradacím a současně musí být schopny řádně rozlišovat mezi různými příznaky, aniž by byly ovlivněny šumem.

(3) Stanovení modelu


Transformace: Pro zarovnání snímaného snímku s referenčním je třeba odhadnout parametry mapovacích funkcí [37-43]. Tyto parametry se vypočítají se zavedenou shodou získanou z předchozího kroku. Citlivost výběru mapovací funkce závisí na předchozích znalostech týkajících se akvizičního procesu a očekávaných deformací obrazu. Pokud neexistují žádné předchozí informace, musí být zajištěna flexibilita modelu pro řešení deformací obrazu.

(4) Transformace obrazu:

Snímaný obraz je transformován pro zarovnání pomocí mapovacích funkcí. Obecně jsou dodržovány výše uvedené kroky registrace obrazu. Nelze vytvořit metodu která by byla univerzální, důvodem je vysoká variabilita snímků a jejich degradace.

Na Obrázek č. 16 Stručný princip transformace snímku kolene, konkrétně natočení o 45° můžeme vidět jednoduchou ukázkou transformace obrazu kdy se na původní snímek aplikuje mřížka natočená o

45° proti směru hodinových ručiček. Při navrácení mřížky do původní polohy zároveň i s překrytým snímkem a provede se rotace. Výsledkem je pak snímek natočený o 45° po směru hodinových ručiček.



(a) Snímek s transformační mřížkou

(b) Otočený snímek

Obrázek č. 16 Stručný princip transformace snímku kolene, konkrétně natočení o 45°

1.3.2 Metody registrace obrazu

(1) Vnější metody: Využívá se umělých cizích předmětů, které jsou k tělu pacienta připojeny, jsou snadno detekovatelné [46-53] a slouží jako externí příznaky, které mají být použity pro porovnávání. Složitost je snížena, a proto je výpočetní rychlost rychlá a také je zachována přesnost. Příkladem jsou markery přilepené na kůži pacienta nebo stereotaktický rám pevně připevněný k vnější lebce pacienta pro účely související s invazivní neurochirurgií.

(2) Povrchové metody: Povrchy, hranice nebo obrysy se na lékařských snímcích obecně liší od orientačních bodů. Například se pro registraci obrazu povrchu mozku se používá povrchový přístup. Tyto algoritmy přiřazování povrchů se obecně používají při registraci rigidních těles. Soubor bodů, je extrahován z obrysů v obraze. Jsou-li pro registraci uvažovány dva povrchy, budou existovat dva takové soubory. Povrch, který pokrývá větší objem pacienta, se obecně považuje pro generování modelu povrchu. Algoritmus iterativního nejbližšího bodu a Algoritmus porovnávání shody se úspěšně používají jako registrační algoritmy pro povrchové techniky [54–63].

(3) Metody momentů a principů os: Ortogonální osy, kolem kterých jsou minimalizovány momenty setrvačnosti, jsou známy jako hlavní osy. Dva shodné objekty lze přesně registrovat tak, že se jejich hlavní osy dostanou do souběhu, aniž by se použily jakékoli rigidní nebo afinní transformace. Pokud objekty nejsou identické, ale vzhledově podobné, mohou být touto technikou přibližně registrovány [16, 64]. U metod založených na momentu se v mnoha případech provádí tzv. předsegmentace, aby se dosáhlo uspokojivých výsledků.

(4) Metody založené na korelaci: Tato metoda je v zásadě užitečná pro registraci jednoúčelových snímků a pro porovnání několika snímků podobného objektu. Má obrovské využití v oblasti lékařských věd pro analýzu a léčbu nemocí. Extrahované rysy ze snímků se také používají k získání koeficientů vzájemné korelace pro registraci obrazu [66-69]. Křížová korelace a fázová korelační technika založená na Fourierově doméně se také používají pro registraci obrazu. Byly vytvořeny úspěšné, ale složité metody za použití přístupu pro odhad frekvence založeného na subprostoru pro problém s registrací

obrazu založeného na Fourierově modelu pomocí algoritmu pro klasifikaci signálů (MUSIC), aby se zvýšila robustnost, což nakonec přineslo přesné výsledky [70]. Pro vyhodnocení transformace mezi dvěma vstupními snímky byly využity techniky založené na Fourierových metodách doplněné o vyhledávací algoritmy [72].

(5) Metody založené na vzájemných informacích: U těchto metod se využívá odhadu společné pravděpodobnosti intenzit porovnávaných voxelů v používaných snímcích. Vzájemné informace mohou být užitečně využity pro stanovení shody mezi vlastnostmi referenčního a snímaného obrazu, jak je uvedeno v kroku shoda příznaků. Korelační metody se ukázaly jako neúčinné pro multimodální registraci. Metody založené na vzájemných informacích však takový problémem netrpí, spíše se zjistilo, že účinně fungují při multimodálních registračních úkolech. K maximalizaci vzájemných informací byly použity metody optimalizace gradientu [73]. K dosažení registrace obrazu pomocí vzájemných informací se také používají okenní a pyramidové přístupy [74]. V současné době jsou pro maximalizaci vzájemných informací přijaty různé optimalizační metody a strategie s více rozlišeními.

(6) Wavelet (vlnkové) metody: Tyto metody využívají informace o času a frekvenci. Pro každou spektrální složku snímku se mění tzv. šířka okna a počítá se její transformace. Šířka okna určuje danou hledanou frekvenci spektrální složky. Čím je okno větší tím menší frekvenci hledáme a naopak. Registrace obrazu na základě vlnky je efektivní. Po výběru několika waveletových koeficientů pomocí pravidel výběru, jako je maximální absolutní waveletový koeficient v multispektrálním obrazu a obrázků s vysokým rozlišením pro jednotlivé pásmo, jsou parciální waveletové koeficienty obrazu s vysokým rozlišením nahrazeny koeficienty z multispektrálního snímku s nízkým rozlišením. Pyramidové přístupy také používají waveletový rozklad kvůli svým vnitřním multirezolučním vlastnostem. Pro nalezení waveletových koeficientů se využívají různé typy vln, jako jsou Haar, Symlet, Daubechies [75] a Coiflets.

(7) Metody založené na tzv. soft computingu: Tyto metody jsou poměrně nové, pokročilé a úspěšně se používají pro úkoly registrace obrázků. Zahrnují umělé neuronové sítě, fuzzy sady a několik optimalizačních heuristik.

- a) Umělé neuronové sítě: Umělá neuronová síť (ANN) je výpočetní model, který je vytvořen na základě biologických neuronových sítí. Je také známá jako vícevrstvý perceptron (MLP), protože obsahuje řadu skrytých vrstev. Tyto vrstvy se skládají ze vzájemně propojené skupiny umělých neuronů, kdy se informace předává z jedné vrstvy do další. Umělé neuronové sítě nebo jednoduše neuronové sítě se adaptivně učí, když informace protékají sítí a podle toho se aktualizují neuronové odkazy přiřazováním různých vah. Na neuronové sítě lze nahlížet jako na nelineární nástroje pro modelování statistických dat, které se používají k modelování složitých vztahů mezi vstupy a výstupy nebo k rozpoznávání vzorců v datech. Existují dva typy schémat: (1) dopředné sítě, kde propojení postrádá jakoukoli smyčku (např. Vícevrstvý perceptron (MLP) a neurální síť s radiální základní funkcí (RBF) a (2) Vracející se sítě, které obsahují smyčky (např. samoorganizující se mapy (SOM) a Hopfieldovy neuronové sítě. Dopředné sítě vyžadují a-priori informace o výstupu pro trénink. Naopak Vracející se sítě nevyžadují žádné takové informace.
- b) Fuzzy metoda: Jedná se o kolekci prvků majících souvislou sekvenci členských tříd. Fuzzy množiny sledují vlastnosti zařazení, sjednocení, doplnění, průniku atd. V klasické teorii množin jsou členské hodnoty elementů v sadě děleny binárně v závislosti na tom, zda prvek patří nebo nepatří do sady. Naproti tomu Fuzzy sady se dělí na základě hodnot získaných díky funkce členství, které se pohybují v intervalu (0,1). Díky tomu fuzzy metody řeší problémy

s nejistotami a nepřesnostmi. Fuzzy sady byly explicitně aplikovány na techniky registrace obrazu [79-80]. Bylo také využito k výběru a předběžnému zpracování extrahovaných funkcí, které mají být registrovány. Fuzzy logika se používá ke zvýšení přesnosti transformačních parametrů což vede k přesným odhadům registrace [81].

- c) Optimalizační heuristika: Úkol najít optimální řešení je velmi obtížný, a to z důvodu četných omezení z pohledu globálního optima. Pro nalezení optima se využívají matematické a objektivní funkce, které mohou být neomezené nebo omezené a mají jak spojité, tak i diskrétní proměnné. Tradiční metody včetně gradientu, dynamického programování a Newtonových metod jsou výpočetně méně efektivní, zatímco poskytují proveditelná řešení ve stanoveném čase. Seznam meta heuristik zahrnuje genetický algoritmus (GA) [82], optimalizaci rojů částic (PSO) [83], algoritmus gravitačního vyhledávání (GSA) [84], optimalizaci kolonií mravenců (ACO) [85-86], stimulované popouštění (SA) [87-88], a algoritmus šíření rostlin (PPA) [89-90] atd.

GA je relativně stará, přibližná vyhledávací technika používaná při práci na počítači. Tato heuristika globálního vyhledávání tvoří důležitou třídu evolučních algoritmů, které napodobují evoluční biologické procesy, jako jsou mutace, selekce a křížení a opuštění. Optimalizace rojů částic a diferenciální evoluce spolu s jejich existujícími variantami jsou relativně pokročilou heuristikou, kterou lze efektivně vyřešit problémy s optimalizací. Tato optimalizační heuristika se aplikuje na problémy s registrací obrazu pro nalezení optimálních parametrů nezbytných pro návrh transformačního modelu [91].

1.3.3 Odhad transformačního modelu

Cílem je navrhnout vhodný transformační model, který transformuje snímáný obraz, s ohledem na obraz původní, s maximální přesností. Transformace, které mohou být provedeny, jsou translace, rotace, škálování, stříh a odraz. Ty transformace se nazývají jako afinní transformace. Existují také projektivní a nelineární transformace. Matematický popis základních, afinních, transformací je dán takto:

- (1) Translace: Bod x má být posunut o velikost t , maticové znázornění transformace pak vypadá takto:

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} t_1 \\ t_2 \end{bmatrix} \quad (1)$$

kde y_1, y_2 jsou nové body, x_1, x_2 jsou původní body, t_1, t_2 jsou translační hodnota.

- (2) Rotace: Bod s souřadnicí $P_1(x_1, x_2)$ se otáčí o úhel θ vzhledem k počátku, pak je vztah mezi konečným bodem $P_2(y_1, y_2)$ a počátečním bodem udán jako:

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} \cos\theta & \sin\theta \\ -\sin\theta & \cos\theta \end{bmatrix} + \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (2)$$

kde y_1, y_2 jsou nové body, x_1, x_2 jsou původní body, θ je rotační parametr.

- (3) Měřítko: Změna měřítka je nutná pro změnu velikosti obrázku nebo pro práci se snímky, jejichž velikost voxelu je rozdílná. Je zastoupena jako:

(3)


$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} s_1 & 0 \\ 0 & s_2 \end{bmatrix} + \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$$

kde y_1, y_2 jsou nové body, x_1, x_2 jsou původní body, s_1, s_2 jsou parametry měřítka.

(4) Střih: Při střihu jsou zachovány pouze rovnoběžné linie. Může být zastoupena jako:

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} * \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} a_{13} \\ a_{23} \end{bmatrix} \quad (4)$$

kde y_1, y_2 jsou nové body, x_1, x_2 jsou původní body, $a_{11}, a_{12}, a_{21}, a_{22}, a_{13}, a_{23}$ jsou parametry střihu. Na Obrázek č. 17 je možné vidět příklad afinních transformací



Obrázek č. 17 Příklad afinních transformací. Translace, rotace, měřítko a střih

2. Studie metod používaných pro segmentaci srdečních struktur

2.1 Porovnání segmentačních metod pro MRI měření srdeční funkce u potkanů

Účelem této práce bylo stanovit přesnost a variabilitu čtyř různých metod segmentace pro měření srdečních funkčních parametrů u potkanů. Měření bylo provedeno jak na zdravých srdcích, tak na srdcích po infarktu.

MRI srdce (dále jen CMRI – Cardiac MRI) se dnes používá pro hodnocení globálních funkčních morfologických parametrů srdce, jako například ejekční frakce (EF), konečný diastolický objem (EDV), konečný systolický objem (ESV), a hmotnost levé komory (LVM). Jako zlatý standard pro měření těchto parametrů u lidí (2) a malých zvířat (3,4) se považuje vysoké prostorové rozlišení CMRI v kombinaci s dobrým kontrastem měkkých tkání.

Hlavními požadavky jsou reprodukovatelnost a přesnost analyzační techniky. Srdeční parametry se běžně počítají z řady snímků pořízených pro celé srdce. Tento výpočet vyžaduje přesnou detekci endokardu a epikardu. Pro segmentaci se převážně používá ruční segmentace, a to z důvodu variace kontrastu a artefaktů toku, které mohou být obtížné pro plně automatické přístupy. Z dřívějších studií bylo prokázáno, že ruční segmentace je o něco přesnější než automatická i když na úkor delší doby analýzy (5).

Cílem této studie je posoudit a ověřit přesnost a variabilitu dvou poloautomatických segmentačních metod pro měření různých srdečních parametrů u zdravých potkanů a potkanů po prodělaní infarktu myokardu. Jako reference se využívá se ruční segmentace.

Materiály a metody

V této studii byly použity čtyři různé metody segmentace:

- Ruční segmentace pomocí softwaru ImageJ (9)
- Poloautomatická segmentace pomocí softwaru Segment – Segment-Off (10)
- Poloautomatická segmentace s automatickou korekcí pohybu na dlouhé ose pomocí softwaru Segment – Segment-On (10)
- Poloautomatická segmentace pomocí softwaru CMRTools

Všechny čtyři metody odhadují změny v srdečních parametrech založené na radiální kontrakci myokardu, a to měřením rozdílů objemu levé komory (LV) při různých srdečních cyklech využívající snímky z pohledu krátké osy. Ruční metody počítají s pohybem dlouhé osy pomocí kritérií zahrnutí řezů a segmentace bazálních řezů, zatímco poloautomatické balíčky CMRTools a Segment nabízejí možnost počítat vliv pohybu dlouhé osy na odhady srdeční funkce pomocí definice roviny. Proto jsme prozkoumali vliv této funkce tím, že jsme ji deaktivovali nebo povolili (Segment-Off a Segment-On). Segment-Off odpovídal za pohyb dlouhé osy stejným způsobem jako ruční segmentace. Pro CMRTools je kompenzace pohybu na dlouhé ose nedílnou součástí modelu použitého pro odhad objemu, a proto jej nelze deaktivovat.

Model akutního infarktu myokardu u potkana

Bylo použito 6 samců potkanů starých 7-8 týdnů (343 ± 21 g), kteří byli uspáni. Následně byli získány snímky srdce. Zvířata následně podstoupila operaci k indukci infarktu myokardu (IM) (11). Po operaci byly, po dvou hodinách od reperfuze, opět získány MR snímky po infarktu myokardu.

Akvizice obrazu

Zobrazování bylo provedeno na 9.4 Tesla VNMRs horizontálním skeneru se stíněným gradientním systémem (400mT/m). Srdeční snímky konvenční orientace (dvoukomorové, čtyřkomorové, a krátké osy) byly získány pomocí podobné metody popsané Schneiderem a kol. (12). Snímalo se také EKG a dechová křivka.

Srdeční fantom

Jako srdeční fantom byly použity srdce dvou exemplářů, které byly vyjmuty a do nich byl implantován balónek který se následně napouštěl třemi různými tekutinami. Bylo získáno se šest datových souborů před MI a šest snímků po MI z pohledu krátké osy.


Analýza obrazu a kritéria zařazení

Aby se dosáhlo větší podobnosti s lidským srdcem byly parametry řezu a rozlišení zvětšeny desetkrát. Byly použity pouze snímky získané z fantomu tedy 6 snímků po IM a před IM. Následně byly analyzovány pomocí čtyř výše zmíněných metod.

Pro ruční segmentaci byly použity pouze snímky krátké osy. Epikardiální a endokardiální kontury byly nakresleny ručně v programu ImageJ. Papilární svaly byly zahrnuty k svalovině levé komory. Koncový diastolický objem (EDV) a koncový systolický objem (ESV) byly identifikovány jako globální maximum a minimum LV dutiny. LVM bylo následně vypočteno jako rozdíl mezi EDV a ESV vynásobeným 1,05 g/ml (15). Ostatní parametry byly vypočteny následovně: Objem úderu (objem krve čerpané při stahu levé komory) $SV = EDV - ESV$; ejekční frakce $EF = 100 * \frac{SV}{EDV}$.

Analýza pomocí softwaru Segment byla zahájena pomocí zabudovaného algoritmu „levého ventrikulárního nástroje“. Nejprve byl vložen počáteční bod do středu LV komory, do něj algoritmus vložil deformovatelný model, který se rozšiřuje směrem k okraji endokardu. Ruční opravy byly prováděny podle potřeby, převážně pro hranici epikardu a endokardu, kde se papilární svaly objevovaly odděleně od myokardu. Pohyb na dlouhé ose byl poté korigován zadáním rozdílu v úrovni mitrální chlopně na konci diastoly a na konci systoly pozorované v pohledu dvou komor. Papilární svaly byly opět považovány za součást LV.

Všechny dostupné řezy byly zahrnuty pro analýzu pomocí CMRTools. Ruční vymezení bylo provedeno v koncových systolických (ES) a koncových diastolických (ED) časových rámcích. Papilární svaly byly považovány jako myokard pomocí nastavení prahu. Je třeba poznamenat, že ačkoli CMRTools má další možnost pro segmentaci papilárních svalů, tato funkce nebyla pro tuto studii použita.



Obrázek č. 18 Segmentační metody, Reprezentativní ilustrace ukazující různé metody segmentace s odpovídajícím vymezením

Kvůli časovým omezením nebylo možné získat datové sady šumu nebo provést další vyšetřování poměru signál/šum (SNR). Jako indikace kontrastu byl relativní kontrast mezi LV krví a myokardem odhadnut ze středního komorového řezu na konci diastoly (ED) a konci systoly (ES) pomocí ImageJ. Relativní kontrast je dán jako rozdíl mezi intenzitou signálu krve a myokardu děleno jejich součtem.

Statistická analýza

Pro srovnání různých metod segmentace byly výsledky prezentovány jako absolutní nebo relativní střední hodnoty \pm SD. Variabilita různých metod jednoho pozorovatele byla dosažena z rozdílů měření mezi první a druhou segmentací pozorovatele A. Variabilita mezi pozorovateli byla odhadnuta na základě rozdílů mezi datovými sadami segmentovanými dvěma pozorovateli A a B.

Výsledky

Přesnost měření objemu fantomu

Objem dutiny LV získaný segmentací snímků krátké osy, získaných z fantomu srdce, byly porovnány s referenčními hodnotami získanými pomocí 3D MR s vysokým rozlišením. Bylo zjištěno, že rozdíly mezi referenčním objemem a objemem získaným pomocí poloautomatických segmentačních metod byly malé (-2,2 a -2,9 μ l), ale statisticky signifikantní v případě manuální segmentace (-8,7 μ l).

Shrnutí srdečních parametrů In Vivo a času segmentace

Referenční měření různých srdečních parametrů získané pomocí manuální segmentace jsou shrnuty v Tabulka 1. Čas potřebný pro ruční segmentaci byl 53 ± 6 minut pro celý dataset 20 ti časových rámců.

Tento čas může být snížen na 22 ± 2 minuty v případě, že byl časový rámec s minimálním a maximálním objemem dutiny vizuálně identifikován a validován měřením dvou předchozích a dvou následujících rámců (segmentuje se pouze 6 snímků místo 20). EDV a ESV byly odvozeny od časového rámce s globálním maximem a minimem objemu. Čas analýzy pro Segment-off a CMRTools byly 17 ± 2 a 32 ± 4 minuty

Variabilita jednoho pozorovatele

Variabilita (podstatný rozdíl v SD) u různých segmentačních metod se pohybuje mezi 2,2 a 3,6 % pro EF, zatímco variabilita pro ESV a LVM byla vyšší a pro EDV nižší. Celkově lze říci, že manuální a Segment-Off metody měli nejmenší variabilitu jednoho pozorovatele.

Variabilita mezi pozorovateli

Pro EF byla variabilita měření mezi pozorovateli pro manuální segmentaci $2,0 \pm 2,8$ %, Segment-Off $-0,8 \pm 3,7$ %, Segment-On $-0,4 \pm 4,8$ % a CMRTools, $-0,8 \pm 3,6$ %, kde Segment-On vykazoval nejvyšší průměrný rozdíl, ale nejvyšší variabilitu. Měření LVM vykazovala nejvyšší variabilitu u všech metod segmentace. U všech ostatních srdečních parametrů vykazovala ruční segmentace nejmenší rozsah variability (62,1 % až 63,1 %), přičemž poloautomatické metody měly rozsah variability větší (Segment-Off: 61,9 % až 63,9 %; Segment-On: 62,5 % až 66,0 %; CMRTools: 63,0 % až 66,3 %).

Porovnání poloautomatické a manuální metody segmentace

Porovnání poloautomatické a manuální metody jsou shrnuty v Tabulka 1 a Tabulka 2. Poloautomatické metody obecně nadhodnocovaly měření EF ve srovnání s manuální segmentací (Segment-Off: $\geq 2,5$ %; Segment-On: $\geq 10,1$ %; CMRTools: $\geq 2,5$ %) Segment-Off vykazoval nejmenší zkreslení a nejmenší variabilitu ve srovnání s manuální segmentací.

Tabulka 1 Souhrn srdečních parametrů

	Tepová frekvence [bpm]	EDV [μ l]	ESV [μ l]	EF [%]	SV [μ l]	CO [ml/min]	LVM [mg]
Kontrola	300 ± 27	$539,7 \pm 27,5$	$179,4 \pm 18,2$	$66,8 \pm 2,2$	$360 \pm 16,7$	$107,9 \pm 6,6$	$545,6 \pm 21,5$
MI	376 ± 20	$480,4 \pm 43,7$	$299,0 \pm 64,9$	$38,0 \pm 10,0$	$181,4 \pm 46,8$	$68,0 \pm 16,6$	$539,7 \pm 27,5$

Tabulka 2 Porovnání poloautomatické segmentační metody s manuální segmentací

	Manual-Segment-Off		Manual-Segment-On		Manual-CMRTools	
	Rozdíl středních hodnot	Relativní rozdíl [%]	Rozdíl středních hodnot	Relativní rozdíl [%]	Rozdíl středních hodnot	Relativní rozdíl [%]
EDV [μ l]	$7,4 \pm 11,9$	$1,5 \pm 2,4$	$6,2 \pm 11,8$	$1,3 \pm 2,4$	$-38,4 \pm 33,9$	$6,9 \pm 5,5$
ESV [μ l]	$6,7 \pm 11,9$	$2,0 \pm 4,5$	$25,5 \pm 13,9$	$10,8 \pm 5,9$	$-15,8 \pm 18,1$	$-7,1 \pm 8,0$
EF [%]	$-0,7 \pm 2,1$	$-2,5 \pm 5,4$	$-4,5 \pm 2,5$	$10,2 \pm 7,1$	$-0,5 \pm 3,6$	$-2,5 \pm 7,7$
SV [μ l]	$0,7 \pm 13,6$	$-1,0 \pm 6,1$	$-19,3 \pm 14,1$	$-8,9 \pm 7,1$	$-22,6 \pm 30,5$	$-9,4 \pm 10,6$
LVM [mg]	$45,1 \pm 34,2$	$7,3 \pm 5,3$	$63,1 \pm 34,0$	$10,5 \pm 5,0$	$-11,7 \pm 51,0$	$-1,8 \pm 7,8$

Závěr

Závěrem je možné říci, že metody poloautomatické segmentace lze efektivně použít pro kvantifikaci srdečních parametrů z MR snímků u potkanů, a doba analýzy může být snížena až o 70 % ve srovnání s ruční segmentací. Variabilita mezi pozorovateli a jednoho pozorovatele byla menší než 3 % pro všechny metody s výjimkou LVM. Kromě toho bylo vypořazováno odlišné zkrácení měření EF ve srovnání s manuální segmentací mezi zdravými srdci a srdci po IM. [9]

2.2 Posouzení pohybu stěny MRI levé komory pomocí výpočtu obrazu amplitudy monogenního signálu

Zobrazování srdeční magnetické rezonance (Cardiac MRI – CMRI) se považuje jako referenční technika používaná pro klinické hodnocení srdeční funkce. Měří se převážně srdeční funkce a jeho rozměry založené na srdečních MRI snímcích alespoň ve třech rovinách (krátká osa, z pohledu dvoukomor a čtyřkomor). Identifikace a lokalizace abnormalit kontrakce, jako je hypokineze nebo dyskineze, je však založena na vizuální interpretaci těchto snímků radiology nebo kardiology, a tudíž trpí vnitřní variabilitou jednoho pozorovatele a mezi pozorovateli. Analýza je založena na srdečním výdeji, koncovému diastolickému (EDV) a systolickému objemu (ESV), objemu úderu (SV), hmotnosti myokardu a ejekční frakce (EF). Tyto parametry označují celkový funkční stav LV, ale neumožňují přesnou lokalizaci rozsahu srdeční kontrakce. Kromě těchto snímků, sekvence pozdního syčení gadolinia (LGE) dává možnost lokalizovat rozsah srdečních patologií díky hyper-zesílenému signálu který se objevuje v oblastech po infarktu.

Nástup sekvence značení může pomoci při identifikaci abnormalit pohybu stěny. Tato metoda spočívá v překrývání magnetizačních sítí zvaných „značky“, které se deformují v koherenci s podkladovou magnetizovanou tkání: pokud se zóna během cyklu nedeformuje, sítě informují o umístění abnormalit. V posledních letech bylo navrženo několik nástrojů pro předběžné zpracování k analýze značených obrázků MRI. Mezi nimi můžeme poukázat na analýzy harmonické fáze (HARP) [11], lokální sinusové modelování (SinMod) [12]. Interpretace označených snímků je časově náročná, z důvodu dalšího zpracování. Pro hodnocení pohybu srdeční stěny byl vyvinut další přístup nazvaný „kódování posunu se stimulovanými ozvěnami“ (DENSE) [14,15]. Tato metoda je založena na výpočtu fází pro generování mapování posunu myokardu schopného znázornit dysfunkci myokardu. Ačkoli technika DENSE vykazuje schopnost analyzovat pohyb stěny, tato metoda není schopna vypočítat měření posunu celým srdečním cyklem kvůli úbytku signálu [16].

Metody optického toku sahají od technik založených na intenzitě po techniky založené na energii a fázi [17–19]. Klasická metoda optického toku je založena na konzistenci intenzity pixelu. Počítá obrazové vektorové pole z časoprostorových derivátů daných intenzitou obrazu. Mezi výzkumy používajícími tento přístup zůstává nejčastěji používanou metodou optického toku Horn a Schunck [20], Lucas a Kanade [21]. Většina těchto technik je citlivá na kvalitu obrazu, šum a změnu jasu v obrazu.

Sledování příznaků – kardiovaskulární magnetická rezonance (FT-CMRI) se v posledních letech projevila jako slibná technika pro hodnocení deformace myokardu, A to díky schopnosti vypočítat několik kvantitativních parametrů, jako je podélné, radiální a obvodové napětí, stejně jako kroucení LV [27,28]. Má však některá omezení, jako je citlivost na pohybové artefakty v rovině a na kvalitu obrazu v sekvenci.

Material a metody

Data byly získány od čtyřiceti pacientů (24 žen a 16 mužů ve věku od 23 do 71 let). Z toho 20 subjektů prodělalo infarkt myokardu, 9 subjektů má myokarditidu, 3 subjekty mají rozšířenou kardiomyopatii a zbývajících 8 subjektů bylo zdravých. Všechny snímky byly získány pomocí 3 T MRI skeneru (Siemens Medical solution, Erlangen, Německo). Pro každého pacienta bylo srdce snímáno z pohledu krátké osy, dvoukomorového a čtyřkomorového pohledu (celkem 25 snímků). Snímky byly získány pomocí True Fast Imaging se sekvencí bez precese v ustáleném stavu (True-FISP), při použití následujících parametrů: TR = 3,5 ms; TE = 1,44 ms, úhel překlpení = 69 °; velikost matice = 176 × 256 pixelů. V této studii byl navržený postup testován na obrazech CMRI v pohledu na krátké osy.

Monogenní signál

Koncept monogenního signálu byl poprvé představen Felsbergem a Sommerem [36,37] jako rozšíření analytického signálu do více dimenzí. Analytický signál se rozkládá na dva ortogonální komponenty, kterým se říká “in phase” (I) and “in quadrature” (Q) komponenty Hilbertovy transformace. Rozklad I/Q umožňuje získání amplitudy a fáze lokálního signálu, kde amplitudy kódují velké energetické změny (tj. Obálku), zatímco fáze kóduje malé strukturální informace, jako jsou hrany a hřebeny. Nicméně signál založený na Hilbertově transformaci má omezené využití, a to pouze na 1D signály. V tomto ohledu získal pozornost monogenní signál založený na Rieszově transformaci. A to jako nástroj pro rozšíření analytického signálu do více dimenzí, jako jsou obrázky (2D) a objemové snímky (3D). Vzhledem k experimentálnímu nastavení je studie omezena pouze na 2D implementaci monogenního signálu [38,39].

V této části jsou představeny hlavní kroky pro výpočet monogenního signálu pro 2D snímek. Monogenní signál S_M snímku I obsahuje tři parametrické snímky $[w, q_1, q_2]$:

$$S_M = w + i * q_1 + j * q_2 \quad (5)$$

kde w je reálná komponenta a q_1, q_2 jsou dvě imaginární komponenty. Reálná komponenta je skutečný obraz $I(x)$ konvolvován s rovnoměrně rotačně invariantním pásmovým filtrem H , zatímco imaginární komponenty q_1 a q_2 jsou výsledky konvoluce skutečné komponenty dvěma lichými kvadraturními filtry h_1 a h_2 .

$$\begin{aligned} w &= I * H \\ q_1 &= w * h_1 \\ q_2 &= w * h_2 \end{aligned} \quad (6)$$

Prvky h_1, h_2 reprezentují liché odezvy filtru. Ve frekvenční oblasti jsou definovány takto [40]:

$$\begin{aligned} h_1 &= \frac{u_1}{\sqrt{u_1^2 + u_2^2}} \\ h_2 &= \frac{u_2}{\sqrt{u_1^2 + u_2^2}} \end{aligned} \quad (7)$$

kde u_1, u_2 jsou horizontální a vertikální frekvenční komponenty.

Výpočet amplitudy pomocí monogenního signálu

Výpočet amplitudy je založen na několika matematických operacích jako Fourierova transformace [33], Fourierova analýza [34, 41], Hilbertova transformace [42].

Pro výpočet dvou amplitudových obrazů na základě monogenního signálu byly použity dva snímky odpovídající koncovým diastolickým (ED) a koncovým systolickým (ES) snímkům. Byl použit sférický

pásmový filtr “Difference of Poisson” (DOP) jako rotačně invariantní filtr “H” [43,44]. Tento filtr je definován Poissonovým jádrovým filtrem a jeho konjugovanými protějšky a je navržen tak, aby vybral malé pásmo původního signálového spektra. Pro každý obraz ED a ES byl každý pixel konvolován s DOP filtrem, čímž byla získána skutečná složka W_{ED} a W_{ES} monogenního signálu. Nakonec byly použity následující výrazy pro výpočet hodnoty amplitudy relevantní pro každý pixel [45]:

$$\begin{aligned} A_{ED} &= \sqrt{W_{ED}^2 + q1_{ED}^2 + q2_{ED}^2} \\ A_{ES} &= \sqrt{W_{ES}^2 + q1_{ES}^2 + q2_{ES}^2} \end{aligned} \quad (8)$$

dále byl vypočítán rozdíl pro každý pixel mezi A_{ED} a A_{ES} , aby se vygeneroval konečný obraz amplitudy:

$$A_{ED} = A = A_{ED} - A_{ES} \quad (9)$$

Na výsledném snímku, se bude synchronní kontrakce v normálním LV projevovat homogenní barvou pixelů, zatímco snížení kontrakce myokardu LV bude reprezentováno jako heterogenní, a to tmavou barvou v obraze amplitudy.

Validační protokol

Na ověření se podíleli tři odborní radiologové (3 roky, 4 roky a 10 praxe s CMRI). Dva z radiologů nejprve ohodnotili kvalitu snímků 40 pacientů na základě 4 bodové stupnice (pro snímky krátké osy): 1 Velmi špatná kvalita; 2: špatná kvalita; 3: přijatelná kvalita; 4: dobrá kvalita. Při tomto hodnocení byly brány v úvahu pouze artefakty, které se obvykle vyskytují v klinické praxi, jako je Ghosting artefakt, rozmazání obrazu a tzv. mis-triggering. Po této analýze byly dva soubory vyřazeny z důvodu špatné kvality. Ze zbývajících datových sad bylo 15 hodnoceno jako majících přijatelnou kvalitu a 23 mající dobrou kvalitu. V této studii bylo použito celkem 38 datových sad MRI.

Stejní radiologové pak prohlíželi snímky, a to anonymně a v náhodném pořadí a klasifikovali je jako normální nebo abnormální. Pro každého pacienta bylo vytvořeno 16 segmentů (6 pro bazální řez, 6 segmentů pro střední bazální řez a 4 segmenty pro apikální řez). Celkově každý z radiologů klasifikoval 608 segmentů. Střed LV a spojení mezi pravou a LV komorou byly ručně definovány jako dva referenční body. V případě neshody dvou radiologů snímky klasifikoval i třetí radiolog a na základě jehož klasifikace bylo rozhodnuto.

Hlavními kritérii pro měření byly: tloušťka myokardu a barevné kódování. Abnormalita pohybu stěny by se projevila fragmentovanými oblastmi nebo náhlou kapkou barvy v monogenním obraze amplitudy signálu. Byla vypočtena citlivost, přesnost, specifická, pozitivní a negativní prediktivní hodnota (PPV a NPV) interpretace abnormalit pohybu stěny s přidáním a bez přidání amplitudového obrazu k obrazům. Kvantitativní proměnné byly vyjádřeny jako střední a mezikvartilní rozmezí.

Tabulka 3 Hlavní charakteristiky studované populace, děleno na základě normální a abnormální LV

Pacienti	Abnormalita LV (n = 32) Medián [25 a 75 percentil]	Normální LV (n = 8) Medián [25 a 75 percentil]
Věk [Roky]	40 [29-64]	50 [43-61]
LVEF [%]	40 [29-53]	60 [56-67]
ESC [ml]	114 [68-131]	59 [43-59]
EDV [ml]	190 [185-201]	133 [106-152]
ESV index [ml/m ²]	57 [44-75]	30 [24-32]
EDV index [ml/m ²]	99 [86-115]	70 [59-82]

Tabulka 4 Výsledky citlivosti, specifity a přesnosti interpretace pohybu stěny bez as parametrickým obrazem amplitudy na základě monogenního signálu

	Radiolog č.1		Radiolog č.2	
	Interpretace CMRI	Interpretace CMRI v kombinaci s Amplitudovým snímkem	Interpretace CMRI	Interpretace CMRI v kombinaci s Amplitudovým snímkem
Citlivost [%]	58,82	71,08	60,29	75
Specifita [%]	78,22	86,88	76,98	89,11
PPV [%]	58,	73,23	56,74	77,66
NPV [%]	78,9	86	79,34	87,59
Přesnost [%]	71,71	81,57	71,38	84,37
Negativní pravděpodobnostní poměr	0,53	0,33	0,52	0,28
Pozitivní pravděpodobnostní poměr	2,7	5,33	2,62	6,89

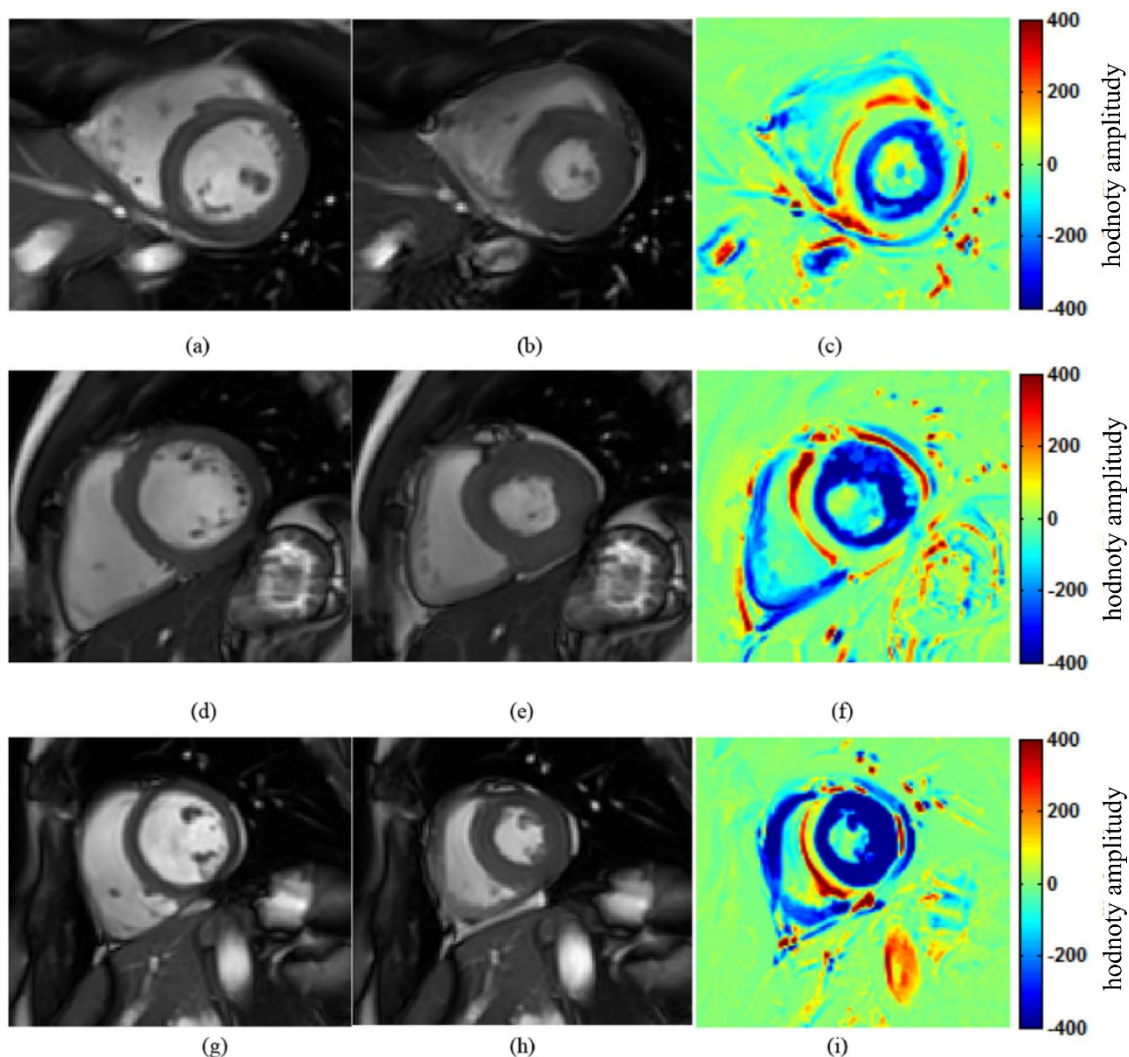
Výsledky

V

Tabulka 3 byly uvedeny hlavní charakteristiky studované populace pacientů, rozdělené podle normální nebo abnormální funkce LV. Ze studovaných 38 pacientů bylo podle zlatého standardu klasifikováno celkem 608 segmentů: 404 segmentů mělo normální pohyb stěny (66 %), zatímco 204 (34 %) segmentů trpělo abnormalitami pohybu stěny.

V Tabulka 4 jsou uvedeny výsledky srovnání interpretace kontrakčních abnormalit pohybem stěny, provedené dvěma radiology, na základě zlatého standardu, s a bez amplitudových obrazů. Výsledky interpretace kontrakčních abnormalit provedených prvním radiologem ve srovnání se zlatým standardem ukazují, že přidání navrhovaného obrazu k obrazům MRI zvýšilo citlivost z 58,82 % na 71,08 % ($p = 0,0094$), přesnost od 71,71 % až 81,57 % ($p = 0,0001$) a specificita vzrostla od 78,22 % do 86,88 % ($p = 0,0012$).

Obrázek č. 19 ukazuje příklad MRI snímků v ED a ES s odpovídajícími vypočítanými amplitudovými obrazy, založenými na monogenním signálu. Ve všech případech je vidět homogenní myokard (modře) bez náhlé změny barvy, což ukazuje na nepřítomnost abnormalit pohybu stěny. [10]



Obrázek č. 19 Koncové diastolické (a,d,g) a Koncové systolické (b, e, h) CMRI snímky levé komory tří pacientů. Snímky c, f a i zobrazují amplitudu získanou pomocí monogenního signálu [10]

2.3 Vyhodnocení poloautomatické metody segmentace pravé komory na MR snímcích s krátkou osou

Účelem této studie bylo zhodnotit poloautomatickou metodu segmentace pravé komory na MR snímcích v pohledu krátké osy s minimálním uživatelským zásahem uživatele. Segmentace se provádí pro všechny obrysy pravé komory v srdeční fázi pomocí jedné „seed“ kontury. Bylo použito dvacet osm po sobě jdoucích krátkoosých, čtyřkomorových a trikuspidálních chlopňových pohledů na vyšetření MRI u zdravých dobrovolníků. Hodnocení provedli dva nezávislí pozorovatelé, kteří hodnotili komorový objem a ejekční frakci.

Příprava dat pro vyhodnocení vyžaduje nejprve segmentaci hran komory. Byly vyvinuty metody automatické segmentace, u nichž bylo prokázáno, že zkracují čas segmentace [7–9] se srovnatelnou nebo dokonce nižší variabilitou než manuální segmentace [9, 10]. Ukázalo se, že jsou prospěšné při hodnocení levé komory (LV) na snímcích z pohledu krátké osy [8, 11, 12]. Segmentace RV je náročnější kvůli vysoké variabilitě tvaru a složitému pohybu [14, 15]. Proto ve rovnání s segmentací LV má nižší výkonnost, pokud jde o variabilitu pro ruční i automatické segmentace [3, 16]. Pro segmentaci RV jsou vhodné algoritmy založené na modelu, které mohou být poměrně účinné, algoritmy založené na obrazu jsou odolnější vůči patologickým změnám a variacím získávání obrazu. Vzhledem k morfologickým variacím RV s ohledem na jeho patologický stav [17] jsou nezbytné robustní segmentační algoritmy.

Materiál a metody

V této studii bylo zařazeno 28 dobrovolníků. Snímky byly získány pomocí skeneru Signa 1,5T (GE Medical Systems, Milwaukee, WI, USA) s parametry: úhel převrácení 45 °, čas echa (TE) nastavený na minimum, opakovací čas (TR) 3 ms, tloušťka řezu 8 mm, mezera 2 mm, počet excitací 0,75, procento fázového zorného pole 0,65, 12 zobrazení / segment a matice 256 × 256. Bylo rekonstruováno 24 fází na srdeční cyklus.

Ruční i poloautomatické segmentace byly provedeny v rámci softwarového balíčku CAAS MRV (verze 4.1; Pie Medical Imaging, BV, Maastricht, Nizozemsko) z pohledu krátké osy. Bazální řez byl odvozen z polohy trikuspidálního prstence z pohledu čtyř komor [3, 14] a trikuspidální chlopně.

Ruční segmentace byla nezávisle provedena dvěma zkušenými radiology s 7 a 2 lety praxe s CMR. Datové soubory byly anonymizovány před samotnou segmentací. První pozorovatel provedl segmentaci jednou a výsledky sloužily jako referenční snímky. Druhý pozorovatel provedl segmentaci dvakrát, a to ve dvou relacích kdy druhá byla provedena za dva týdny. Tím bylo dosaženo odstranění variability jednoho pozorovatele.

Poloautomatický algoritmus segmentace RV je založen na rámci buněčných automatů, který umožňuje, aby byl každý voxel označen jako popředí nebo pozadí. Tento proces značení je implementován pomocí technik paralelního výpočtu. Algoritmus segmentace vyžaduje předchozí informace o ED a ES fázích a apikální a bazální řezy pro ED a ES fáze. Ve fázích ED a ES uživatel načrtne hrubý náčrt endokardiální kontury RV jako počátek seed funkce. Segmentace je iniciována v řezu, kde uživatel definoval zhruba danou konturu RV, která je použita algoritmem během procesu značení v popředí. Mezitím je označení pozadí určeno algoritmem založeným na vlastnostech odvozených od samotného obrazu a pohybu srdce extrahovaného z řezu na krátké ose. Stejní dva pozorovatelé provedli poloautomatickou RV segmentaci (výsledkem bylo měření A1, A2a a A2b, v Tabulka 5 je uveden přehled měření).

Tabulka 5 Přehled měření a analýz

Manuální měření	
M1	Manuální segmentace prvním pozorovatelem
M2a	První pokus manuální segmentace druhým pozorovatelem
M2b	Druhý pokus manuální segmentace druhým pozorovatelem
Poloautomatické měření	
A1	Poloautomatická segmentace prvním pozorovatelem
A2a	První pokus poloautomatické segmentace druhým pozorovatelem
A23	Druhý pokus poloautomatické segmentace druhým pozorovatelem
Manuální analýza	
Variabilita jednoho pozorovatele	M1 vs M2a
Variabilita mezi pozorovateli	M2a vs M2b
Poloautomatická analýza	
Variabilita jednoho pozorovatele	A1 vs A2a
Variabilita mezi pozorovateli	A2a vs A2b
Platnost	A1 vs M1

Ventrikulární objemy ve fázích ED a ES byly pomocí softwaru automaticky vypočteny pomocí Simpsonova pravidla:

$$Volume = \sum_{i=1}^n Area_i Thickness_i \quad (10)$$

kde i je úroveň řezu, n je počet řezů, $Area_i$ je oblast pokrytá endokardiálními konturami RV na úrovni i -tého řezu a $Thickness_i$ je tloušťka řezu na i -té úrovni. EF byl také automaticky vypočítán pomocí následující rovnice:

$$EF = \frac{ED_{volume} - ES_{volume}}{ED_{volume}} * 100\%, \quad (11)$$

Pro vyhodnocení výkonu poloautomatického segmentačního algoritmu byly ED a ES komorové objemy pro pravé endokardium, stejně jako hodnoty pro EF, porovnány s manuálně odvozenými hodnotami prvního pozorovatele (měření A1 vs. měření M1). Obrisy získané algoritmem poloautomatické segmentace byly také vyhodnoceny v porovnání s manuální segmentací pomocí dvou metrik: kostkových metrik (DM) a Hausdorffovy vzdálenosti (HD). DM je míra překrývání se plochy mezi dvěma obrysy pomocí následující rovnice:

$$DM = \frac{A \cap B}{A + B} \quad (12)$$

kde A a B jsou oblasti uzavřené dvěma testovanými obrysy. Hodnota DM se pohybuje od 0 (bez překrytí) do 1 (perfektní překrytí). Mezitím HD je míra maximální vzdálenosti mezi dvěma obrysy vyjádřená v mm pomocí následující rovnice:

$$HD = \max \left(\max_{x \in X} \left(\min_{y \in Y} d(x, y) \right), \max_{y \in Y} \left(\min_{x \in X} d(x, y) \right) \right) \quad (13)$$

kde X a Y jsou dva testované obrysy, x a y jsou jednotlivé body X a Y, $d(x, y)$ je euklidovská vzdálenost mezi body x a y .

Variabilita mezi pozorovateli manuálních segmentací byla získána porovnáním výsledků segmentace prvního pozorovatele a prvního výsledku druhého pozorovatele (měření M1 vs M2a) a variabilita jednoho pozorovatele dvěma výsledky segmentace druhého pozorovatele (měření M2a vs M2b).

Tabulka 6 Charakteristiky studie a základní měření pravé komory

	Všichni	Muži	Ženy
Počet	28	14	14
Věk [roky]	35,5 ± 6,5	33,3 ± 7,6	30,6 ± 5,6
Váha [kg]	72,0 ± 10,6	76,4 ± 9,3	67,5 ± 10,1
Srdeční tep [blm]	72,1 ± 12,1	72,1 ± 12,9	72,1 ± 12,0
ED objem [ml]	166,2 ± 37,4	182,8 ± 40,2	149,6 ± 26,5
ES objem [ml]	74,5 ± 21,7	84,6 ± 23,6	64,5 ± 14,2
EF [%]	55,3 ± 6,5	53,8 ± 6,9	56,9 ± 5,8


Výsledky

Tabulka 6 ukazuje charakteristiky účastníků studie včetně jejich objemů ED, ES a velikosti EF. Celkový průměrný věk účastníků byl 30,5 ± 6,5 let. Typický výsledek poloautomatické segmentace RV je znázorněn na Obrázek č. 20.

Při ruční segmentaci u objemů ED byla variabilita mezi pozorovateli větší než variabilita jednoho pozorovatele a menší u objemu ES.

Poloautomatická segmentace prokázala dobrou shodu s manuální segmentací s vynikající lineární korelací pro objemy ED i ES (R^2 0,98 a 0,91) a mírně menší, ale stále dobrou korelací pro EF (R^2 0,79). Objemy ED měly střední rozdíl menší než 2 ml (0,91 %), objemy ES měly průměrný rozdílem menší než 4 ml (- 4,84 %).

Pro poloautomatickou detekci kontury nebyly pozorovány žádné významné rozdíly mezi prvním a druhým pozorovatelem. První a druhé měření druhého pozorovatele ukázaly významné rozdíly v objemech ES a EF. Variabilita poloautomatických segmentací mezi pozorovateli a jednoho pozorovatele byla znatelně menší než u manuální segmentace. [11]



Obrázek č. 20 Dvoukomorové snímky krátké osy automatické segmentace pravé komory na konci diastolické (levý sloupec) a systolické fáze (pravý sloupec). Bazální řezy, uprostřed dutiny a apikální řezy (obrázky nahoře, uprostřed a dolní řádky). Plné modré a přerušované červené čáry představují obrysy epikardu levé komory a kontury endokardu. Čárkované zelené čáry představují kontury endokardu pravé komory. [11]

2.4 Plně automatická segmentace 4D MRI pro funkční měření srdce


Segmentace srdečních lékařských obrazů je důležitý krok v měření srdeční funkce, obvykle se provádí buď manuálně, nebo poloautomaticky. Plně automatická segmentace LV, RV a myokardu ve 3D pomocí magnetické rezonance (MR) během celého srdečního cyklu (čtyřdimenzionální, 4D) je poměrně náročná. Tato studie navrhuje metodiku založenou na deformaci pro efektivní segmentaci 4D (3D + čas t) CMR snímků.

Pro diagnostiku, monitorování a léčbu těchto patologických stavů je k dispozici řada způsobů zobrazování srdce, včetně: magnetické rezonance (MR), počítačové tomografie (CT), echokardiografie (ECHO) a nukleární medicíny. Srdeční kontraktilita může být kvantifikována z měření objemů komory, ejekční frakce a zbytnění srdeční stěny. Tyto kvantifikační metody vyžadují segmentaci levé a pravé komory (LV a RV) na snímcích CMR. Ve srovnání s 2D zobrazováním poskytuje 3D zobrazování zvýšení poměru signál-šum (SNR), souvislé objemové pokrytí, tenčí řezy. A umožňuje přesnější měření srdečních objemů, jeho funkcí, snížení chyby v registraci a pružnější postprocessing.

Segmentace srdce byla provedena vymezením hranice endokardu a epikardu LV komory a obrysu RV komory. Ten je obvykle příliš tenký, aby šlo rozlišit hranici endokardu a epikardu. Nejprve byl segmentován endokard LV pomocí Houghovy transformace a metody lokální Gaussovy distribuce (LGD); jakmile bylo endokardium rozděleno na segmenty, byl segmentován LV epikard a obrys RV pomocí předem navržené metody level setbased shape prior (LSSPM).

Metodika

Bylo použito plně automatické předzpracování včetně oříznutí oblasti zájmu (ROI), odstranění šumu a vylepšení kontrastu pro zlepšení účinnosti a spolehlivosti segmentace. Na základě 3D obrazů srdce před segmentací nejprve vytvořeno oříznuté zorné pole (FOV), soustředěné na srdce. Pro detekci změn signálu byla vypočtena série gradientních snímků mezi sousedními časovými rámci. Na tyto gradientní snímky byla použita projekce maximální intenzity v čase (MIPT). Vypočtené těžiště na tak zvaných MIPT obrazech bylo poté identifikováno jako střed srdce a byl vybrán jako střed oblasti zájmu (ROI nebo oříznutý FOV) pro segmentaci. Diagram předzpracování obrazu je vidět na Obrázek č. 21.



Obrázek č. 21 Diagram předzpracování obrazu

Kontury využívající Houghovu transformaci

Obrys endokardu LV má vysoký kontrast mezi krevním poolem a myokardem a je obecně kruhový na snímcích srdce získaných v pohledu na krátké osy. To nám umožňuje použít Houghovu transformaci k odvození počátečního kruhového obrysu. Jediným parametrem v Houghově transformaci je poloměr, který není znám. V této studii byl počáteční poloměr Houghovy transformace odhadnut v rozsahu $[1/8, 1/2] \times \text{délka FOV}$. Tento proces byl nejprve použit na oříznutém FOV středního řezu LV pro první časový rámeček, poté byla detekována počáteční kontura použita v následných krocích pro segmentaci LV. Původní kontura LV byla dvojnásobně zvětšena tak aby pokryla RV. Tvar RV není kruhový, proto byl použit algoritmu LSSPM a booleovské operace k deformaci kruhového obrysu, aby kopíroval tvar RV.

Segmentace LV

Segmentace LV aplikuje Houghovu transformaci [29] a LGD pro segmentaci endokardu LV ze 4D ($3D + t$) a poté segmentuje hranici epikardu. Epikard má nízký kontrast vůči sousedním tkáním, na rozdíl od endokardu, který odděluje krev s vysokou intenzitou signálu od myokardu s nízkou intenzitou signálu. Je proto obtížnější vymezit obrys epikardu stejnými metodami, které fungují pro segmentaci kontur endokardu. Proto se nahradí intenzita signálu voxelů v LV komoře střední hodnotou jedné vrstvy voxelů mimo LV komoru.

LDG segmentace

Model lokální Gaussovske distribuce (LGD) je implicitní metoda aktivní kontury založená na distribuci lokální intenzity. Předpokládáme, že obrazová doména může být rozdělena do dvou oblastí uvnitř a vně sady nulové úrovně, které jsou označeny jako $i = 1$ a $i = 2$. Rovnici pro energii segmentace LGD lze napsat takto:

$$E_{LDG} = - \int \omega(x - y) \log P_{1,x}(I(y)) H(\theta(y)) dy - \int \omega(x - y) \log P_{2,x}(I(y)) H(\theta(y)) dy, \quad (14)$$

kde I je obraz, který má být zpracován, θ je funkce vzdálenosti, H je Heaviside funkce, $P_{i,x}(I(y))$ je hustota pravděpodobnosti, ω je nezáporná váhová funkce, vybraná jako zkrácené Gaussovo jádro, x označuje bod v obrázku, y představuje bod v kruhovém sousedství kolem x s malým poloměrem ρ . Pro modelování hustot pravděpodobnosti předpokládáme, že průměr a rozptyl LGD jsou prostorově proměnné parametry.

LSSPM segmentace

Vzhledem k předpokladu, že zdravý epikard je ohraničen eliptickým obrysem, byl přidán k metodě nastavení úzkých pásem termín elipsy a podobnost, aby byla zpřesněna segmentace. Energie segmentace LSSPM lze pak definovat takto:

$$E = E_{level\ set} + \alpha E_{elipsa} + \beta E_{podobnost}, \quad (15)$$

kde $E_{level\ set}$ představuje termín level set, E_{elipse} představuje předešlý elipsovitý tvar a $E_{similarity}$ reprezentuje termín podobnosti. α a β jsou pozitivní hyperparametry, které vyrovnávají vliv obou termínů. Pokud je α a β nízká, například v extrémním případě $\alpha = 0$ a $\beta = 0$, znamená to použití tradiční úzkopásmové segmentace; když α je vysoká, obrys segmentace bude blíže elipse. V uvedených experimentech byly α a β nastaveny na 0,5 a 0,2, což zapříčinilo, aby se kopírovaly skutečné obrysy.

Měření srdeční funkce

V této studii byla použita navrhovaná metoda segmentace k získání srdečních měření, která jsou klinicky důležitá, jako objem komory, objemu stahu, ejekční frakce, srdeční výdeje a tloušťka stěny myokardu levé komory. Levý ventrikulární koncový diastolický a koncový systolický objem (LVEDV a LVESV) jsou hodnoty množství krve v levé komoře, zahrnující tkáň myokardu, objem levé srdeční komory (LVSV) je definován jako množství krve vypuzené ze srdce během každé kontrakce ($LVSV = LVEDV - LVESV$). Ejekční frakce levé komory (LVEF) je definována jako poměr krve čerpané ze srdce v každém rytmu ($LVEF = LVSV / LVEDV$) a srdeční výdej (LVCO) definovaný jako minutový srdeční výdej ($LVCO = LVSV \times \text{srdeční frekvence}$).

Manuální segmentace

Manuální segmentace byla použita jako základ pro vyhodnocení automatické segmentace, kde se používá tzv. Hodnota kostky pro měření překrytí mezi ruční a automatickou segmentací. Pro nakreslení manuálních obrysů byl použit nástroj softwaru MavisLab.

Hodnotící kritéria

Výsledky byly vyhodnoceny porovnáním segmentace pomocí „kostkového koeficientu“, který je definován jako poměr průniku RA a RM k jejich sumě.

$$Dice\% = \frac{2|R_A \cap R_M|}{|R_A| + |R_M|} * 100\%, \quad (16)$$


kde RA je navrhovaný výsledek segmentace a RM jsou výsledky z manuální segmentace a $||$ označuje počet pixelů v odpovídajícím objemu. Čím větší je koeficient kostky, tím lepší je shoda výsledků segmentace mezi dvěma metodami (1 znamená dokonalé překrytí a 0 znamená, že se nepřekrývají vůbec). Kromě toho byl vypočítán variační koeficient (CV) jako statistická míra přesnosti segmentace,

$$CV = \frac{d}{\mu} * 100\%, \quad (17)$$


kde d představuje standardní odchylku a μ je průměrná hodnota kostky.

Výsledky

K vyhodnocení výsledků segmentace LV a RV bylo použito simulované dynamické srdeční akvizice. Síňový fantom MRXCAT byl segmentován navrhovanou metodou. Pro segmentaci bylo vygenerováno celkem 24 fází v celém srdečním cyklu. Byly testovány dva SNR (poměry signál-šum) a to 50 a 25. Obrázek č. 22a a 22b ukazují výsledky segmentace v ED a ES fázi. Obrysy získané z LSSPM se dobře shodují s hranicemi fantomu, s vysokými koeficienty kostky $98,72 \pm 1,75$ % pro LV endokard, $97,12 \pm 2,12$ % pro LV epikard a $98,96 \pm 0,52$ % pro RV, na základě SNR 50, a s $97,63 \pm 1,51$ %, $96,13 \pm 0,89$ % a $96,73 \pm 1,28$ %. [12]



Obrázek č. 22 Segmentace LV endokardu (zelená), LV epikardu (červená) a RV (modrá) na numerických snímcích fantomu pomocí LSSPM, na konci diastoly (a, c) a na konci systoly (b, d). Byly testovány dva SNR (a, b: 50; c, d: 25).



Obrázek č. 23 Schematický diagram segmentace LV: LGD byl použit pro získání LV endokardu a LSSPM byl použit pro získání LV epikardu. [12]

2.5 Segmentace myokardu z DE MRI s náhodnými cestami a rozptýleným zobrazením tvaru

MRI se zpožděným vylepšením (DE) je účinnou a dobře validovanou zobrazovací technikou pro detekci a hodnocení infarktu myokardu (MI) [1]. DE obrazy jsou získávány s 10–15minutovým zpožděním po intravenózním podání kontrastního gadolinia a potlačený signál je získán v normálním myokardu, který je v infarktových oblastech hyper-zesílen [1, 2]. Většina stávajících akademických prací, které se týkají DE MRI, se zaměřuje na automatickou lokalizaci a kvantifikaci infarktových oblastí, zatímco se předpokládá, že již bylo dosaženo vymezení myokardu. [3–9]. Dosažení tohoto cíle však může být náročné, především kvůli vlastnostem DE snímků. Zaprvé, hyper-zesílená infarktová oblast a potlačená zdravá oblast mají za následek heterogenní intenzitu myokardu. V jiných MRI sekvencích, jako je široce používaný CMRI, se často předpokládá rovnoměrné rozdělení intenzity myokardu [11, 12]. Za druhé, rozsah intenzity myokardu se překrývá s rozsahem intenzity okolních tkání [10, 13] a často není možné pozorovat žádnou zřetelnou hranici. Zařetí, vzory zlepšení jsou komplexní. Poloha, velikost a tvar infarktových oblastí se mezi pacienty výrazně liší. Může dojít také k mikrovaskulární obstrukci (MVO), která se objevuje jako potlačená oblast (kvůli nedostatku absorpce kontrastního činidla) v hyper-zesílené infarktové oblasti [2, 14].

Segmentaci myokardu v DE MRI lze dosáhnout přímou segmentací z CMRI. Pro tuto propagaci byly navrženy různé registrační metody, jako je 2D rigidní registrace založená na posuvném okně [15],

afinní transformace [16] a rigidní registrace, která zahrnuje tok multiscale celkového variačního toku [17]. Ovšem rigidní nebo afinitní registrace nemusí být schopná zachytit deformace.

K detekci obrysů v DE snímcích, Ciofolo et al. navrhl 2D geometrickou šablonu, kde byl myokard modelován jako uzavřená struktura pásu s imaginární střednicí a variabilní šířkou [18]. Wei a kol. navrhl 1D parametrický model pro detekci spárovaných okrajových bodů endokardu a epikardu, kde byly modelovány intenzitní vzorce podél radiálních paprsků od středu LV po epikard [19].

Výsledky segmentace CMRI jsou silné informace, které mohou segmentaci zjednodušit [19]. Ovšem dýchací pohyby a rozdíly v objemu hrudního plynu mezi zadržením dechu však mohou zabránit tomu, aby DE CMRI pokryly stejný prostor srdce [10]. Kromě toho může být vyžadován odborný dohled ve stadiu segmentace MRI a ve fázi registrace CMRI a DE MRI [19], což omezuje minimalizaci interakce člověka.

Tato práce se liší od stávajících metod ve třech aspektech. Nejprve dochází k prozkoumání možnosti vyloučení silné závislosti předsegmentovaného CMRI a použije se tvarový model k poskytnutí předchozích informací. Zadruhé, pro udržení tvarových znaků každé šablony tvarů a dosažení dostatečné flexibility je použita technika rozptýlené reprezentace k vytvoření modelu tvaru. Zatřetí, pro extrakci informací ze snímků DE se používá metoda založená na náhodných cestách. Předcházející tvarový model je také integrován pro vytvoření naváděných náhodných cest.

Materiál a metoda

Jako testovací data byly použity snímky DE MRI od 30 pacientů s infarktem myokardu (MI). Rozlišení DE MRI bylo $0,722 \times 0,7292 \times 5$ mm. Každý snímek obsahoval 10–18 řezů krátkou osou s rozlišením 490×490 pixelů. Pozorovatel s odbornými znalostmi v oblasti anatomie srdce ručně vymezil hranice myokardu na všech snímcích, aby vytvořil tzv. „zlatý standard“ pro vyhodnocení. Kromě toho pro studii jednoho pozorovatele bylo náhodně vybráno 10 pacientů z dat pro další manuální segmentaci. Tuto segmentaci provedl nezávisle jiný odborník, který neměl přístup k segmentaci prvním odborníkem.

Protože počet získaných datových souborů DE je omezený, byla stažena tréninková data z Cardiac MR Left Ventricle Segmentation Challenge (2009) [23], aby se získal počáteční tvar myokardu. Byly vybrány dvě specifické kategorie dat, zahrnující infarkt myokardu a zdravé srdce. Pro modelování předchozího tvaru, který obsahuje 21 subjektů a celkem 201 řezů, byla použita ruční segmentace z ED fáze vybraných subjektů.

Metoda je popsána v pěti částech, a to inicializace založená na atlasu, konstrukce slovníku specifického pro cíl, řídký reprezentativní tvarový model, řízené náhodné cesty a iterační rámec. S 201 řezy MR z datové sady Challenge lze vytvořit úložiště šablon tvarů. Z důvodu velké tloušťky řezu v DE MRI je informace o tvaru mezi řezy nespojitá. Jako šablony tvarů se proto používají 2D řezy. Místo použití explicitního parametrického znázornění tvaru [26, 27] se reprezentuje manuální segmentace každého řezu jako maska (matice), kde je pozice myokardu označena jako 1 a zbytek je označen 0, podobně jako v [28]. U každého cílového řezu se pouze malá sada šablon podobá velikosti a tvaru cílového myokardu. Používání všech šablon proto nemusí být nezbytné pro efektivní modelování. Proto se používá koeficient podobnosti kostek (DSC) mezi šablonami a počáteční segmentací v případě že podobnost nepřekročí určitý práh bude šablona pro daný řez vyřazena. Vybrané šablony se potom použijí k vytvoření slovníku pro jednotlivé řezy, $D_r [s_{r1}, s_{r2}, \dots, s_{rn}]$, kde index r představuje r -tý řez v cílových datech a n je celkový počet šablon tvarů, které jsou vybrány pro r -tý řez.

Kvůli nezřetelným hranicím a komplexní variabilitě tvaru srdce jsou pro získání výsledku automatické segmentace s realistickým tvarem srdce zásadní předchozí znalosti. Tvar myokardu byl modelován pomocí slovníku složek D_r a jejich rozptýlené lineární kombinace. Aby bylo možné přizpůsobit tvarový model cílovým obrazům a dosáhnout výsledků segmentace, musí být také analyzovány informace o intenzitě v DE snímcích. Za tímto účelem je použita metoda náhodných cest a integruje se předchozí tvar, pro vytvoření řízené náhodné cesty. Metoda náhodných cest je algoritmus segmentace založený na grafech, kde se se snímkem zachází jako s grafem $G = (V, E)$ se sadou vrcholů V a sadou hran E . Namísto manuálně označenému počátku seed funkce byl použit předchozí tvar k vedení náhodných cest. S ohledem na cílový obraz je vytvořen 2D předchozí tvar pro každý řez, to znamená y_r^{shape} pro r -tý řez. Označí se předchozí tvar pro všechny řezy, a to pomocí y_r^{shape} . Energetická funkce je navržena jako:

$$E_{(x)} = \frac{1}{2} \sum_{e_{ij} \in E} \omega_{ij} (x_i - x_j)^2 + \gamma * \frac{1}{2} \sum_{i \in V} (x_i - y_i^{shape})^2, \quad (18)$$

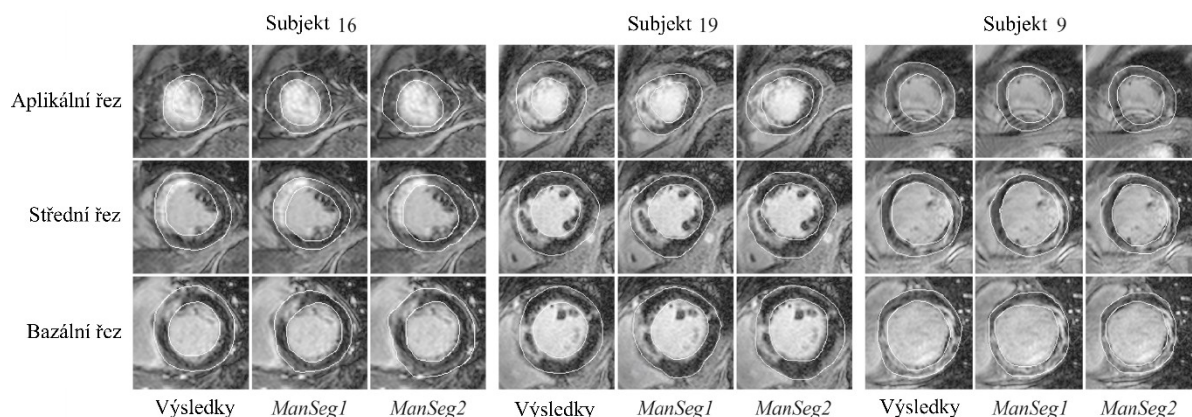
kde x_i představuje pravděpodobnost myokardu ve voxelu i a γ je váhový parametr. Hodnoty okrajů na základě rozdílu intenzity mezi vrcholy se vypočítají takto:

$$\omega_{ij} = \exp(-\beta(I_i - I_j)^2), \quad (19)$$

kde I_i je intenzita obrazu voxelu i a β je nastavitelný parametr, který řídí citlivost na kontrast intenzity. První termín v rovnici výše je termín konvenčních náhodných cest. Když sousední voxely mají podobné intenzity I_i a I_j , hodnota okraje ω_{ij} je blízko 1. Tak, minimalizace prvního členu vede k podobným pravděpodobnostem x_i a x_j . Na rozdíl od toho, když jsou intenzity odlišné, má hmotnost ω_{ij} tendenci se přibližovat k nule. Potom pravděpodobnosti x_i a x_j se navzájem neovlivňují. Druhým termínem je navrhovaný předem regulovaný termín, který řídí hodnotu x_i směrem k hodnotě předchozího tvaru y_i^{shape} .

Analýza výkonu

Pro kvalitativní vyhodnocení byly výsledky segmentace bazálních, středních a apikálních řezů od 3 subjektů jsou znázorněny na Obrázek č. 24, spolu s ruční segmentací od dvou pozorovatelů. Výsledky navrhované metody byly také kvantitativně vyhodnoceny porovnáním s manuálním vymezení prvním pozorovatelem, který byl proveden na všech datech. A srovnávané metody byly navrženy tak, aby vyhodnotily účinnost každé části dané metody. Dále byly studovány účinky velikosti úložiště tvarů a počtu iterací.



Obrázek č. 24 Automatická a manuální segmentace tří subjektů

Hodnoticí parametry

Metoda byla ověřena na 30 MRI datových souborů od pacientů s infarkty myokardu. Pro kvantitativní vyhodnocení navržené metody byly použity DSC a tvarová podobnost (SS) [31] a následné porovnání výsledků segmentace se zlatým standardem. Metrika SS je funkcí úhlu mezi normálními vektory dvou hranic. Hodnota SS se pohybuje v rozmezí od 0 do 1, čím větší hodnota je tím jsou si dva tvary podobnější.

Generalizace metody pro nepozorované údaje

Pro otestování zobecnění navrhované metody na rutinní klinické snímky, byly shromážděny DE obrazy 10 nových pacientů. Tyto data se nepoužila během vývoje metody a ladění parametrů. Výsledky pro 10 nových obrázků: $76,02 \pm 7,43$ % pro DSC a $82,15 \pm 4,93$ % pro SS.

Vliv velikosti úložiště šablon tvarů

Účinky jsme testovali pomocí různě velkých sad tvarových šablon. A to 21 datových sad (201 řezů), 12 datových sad (118 řezů) a 6 datových sad (56 řezů). Tabulka 7 demonstruje, že relativně malá sada šablon tvarů může efektivně reprezentovat tvary myokardu.

Tabulka 7 Vliv výběru tvarových šablon vyhodnocených pomocí DSC (%)

	21 data setů	12 data setů	6 data setů
DCS	$74,60 \pm 7,79$	$73,75 \pm 6,84$	$73,56 \pm 6,32$
SS	$79,92 \pm 5,88$	$79,23 \pm 5,91$	$78,60 \pm 5,59$

Vliv rozdílného počtu iterace

Pro studium vlivu rozdílného počtu iterací, byly měřeny průměrné DSC s ohledem na množství iteračních kroků. Bylo zjištěno, že DSC začne konvergovat, v případě, že počet iteračních kroků dosáhne 13 a více. Průměrná doba byla vypočtena pro DE data od jednoho pacienta, z nichž průměrný počet řezů byl 15. Doba potřebná pro inicializaci založenou na atlasu byla $6,03 \pm 1,60$ min, a pro každou iteraci $20,61 \pm 4,62$ s. Pokud je počet iterací nastaven na 20, celkový čas segmentace byl asi 13 minut. [13]

2.6 Bezsegmentační objemová metoda pro rychlou vizualizaci smykového napětí cévní stěny pomocí 4D průtokového MRI

Cílem této práce bylo vyvinout rychlou bezsegmentační metodu vizualizace a výpočtu stříhového napětí ve stěně (WSS) aorty pomocí 4D Flow MRI. WSS je fyzicky definována jako změna rychlosti tekutiny na endotelu ve směru lumenu cévy. Tato síla je ovlivněna vaskulární geometrií, turbulentním prouděním a jinými hemodynamickými poruchami. Abnormální hladiny WSS jsou spojeny s kardiovaskulárními onemocněními jako ateroskleróza, aortální disekce nebo formování aneurysmat. Předchozí metody pro výpočet WSS spočívaly v náročné manuální segmentaci hranic.

Výpočet WSS tedy vyžaduje prostorově rozlišená rychlostní data a vymezení endoteliálních hranic. 4D Flow MRI má potenciál pro umožnění neinvazivního in vivo měření WSS, protože vyhodnocuje jak rychlost krve, tak anatomii pacienta.

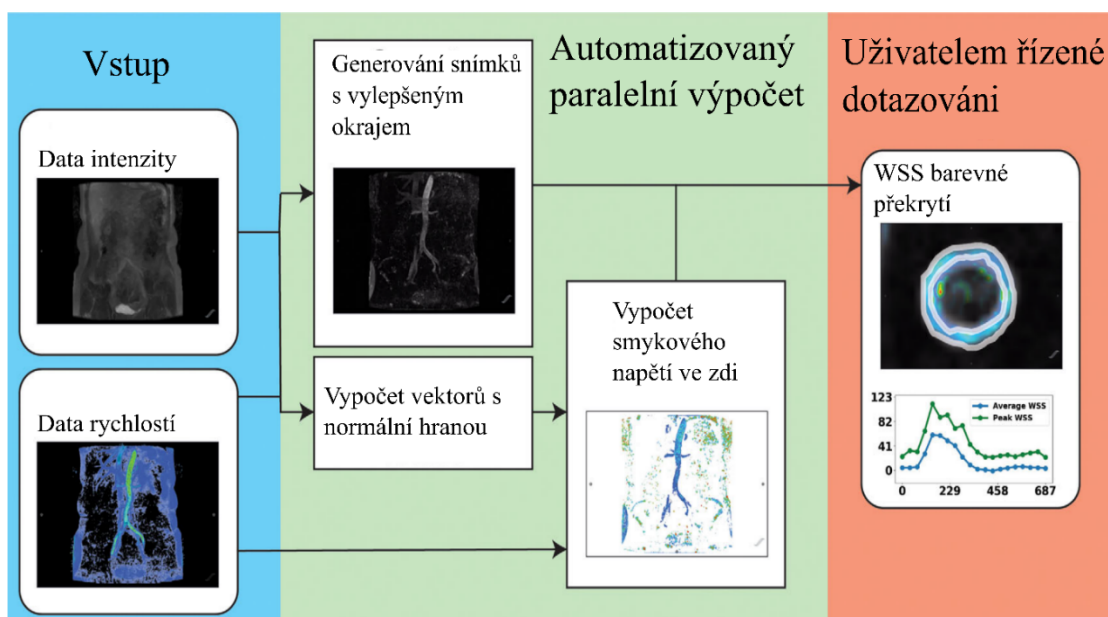
Manuální segmentace je náročná na čas a může vést k velké variabilitě mezi pozorovateli. Zároveň dalším omezením je vysoký počet oblastí zájmu (ROI) jelikož aorta je elastická a pohybuje se v čase. Proto byla navržena metoda automatická. Pro ověření byly výsledky této metody porovnány s výsledky získanými pomocí referenční metody Potters a kol. [8].

Metodika

Snímání MRI 4D Flow se provádělo s použitím intravenózního gadolinia. Parametry získávání MR jsou uvedeny v Tabulce 8. Výpočty smykového napětí v celém vektorovém poli byly provedeny v programu MATLAB 2016b. Metody jsou dále optimalizovány pomocí paralelního výpočetního nástroje MATLAB. Volumetrická vizualizace byla provedena pomocí Arterys Cardio DL 2.3 (Arterys, San Francisco, CA). Pro vyhodnocení WSS bylo potřeba ručně nakreslit ROI na rozhraní cévy a lumenu v programu Arterys. Jako hodnotu viskozity krve, která byla považována jako nestlačitelná newtonská kapalina, bylo použito 3,2 mPa/s. Pro explicitní kvantifikaci WSS jsou uvedeny dvě metriky, které se počítají v každém časovém kroku. První metrika je průměrná WSS, která byla určena průměrem WSS uvnitř ROI. Druhou metrikou je vrchol WSS, což je maximální hodnota WSS detekovaná v ROI. Průměrná WSS během vrcholové systoly je maximální hodnota průměrného WSS s ohledem na čas. V žádném z případů předložených před kvantifikací nebyla provedena explicitní segmentace. Metoda: (1) využívá se algoritmus pro výpočet WSS, který je nezávislý na uživateli, (2) efektivně vypočítá WSS v každém voxelu napříč prostorem a časem a (3) umožňuje rychlou lokalizaci oblastí aberantního WSS. Schéma algoritmu je k nahlédnutí na Obrázek č. 25.

Tabulka 8 Parametry získávání 4D toku obrazu a faktory zrychlení pro pseudonáhodné podvzorkování s proměnnou hustotou

ID případu	Objem zobrazení	Získané rozlišení (mm)	Získaná matice	Řezy	Rychlost kódování (cm / s)	Časové rozlišení (ms)	Zrychlení (fáze x řez)	Čas skenování (mm:ss)
1	Sagitální	3,00x2,50x1,88	192x255	60	250	61	1,8x1,8	13:33
2	Koronární	2,08x2,80x1,79	192x224	80	200	36	3,2x1,8	11:28
3	Koronární	1,88x2,80x1,41	192x256	80	250	40	3,0x2,0	12:38
4	Sagitální	3,00x2,38x1,98	160x192	54	250	50	1,8x1,8	11:12



Obrázek č. 25 Algoritmus pro určování a vizualizaci WSS

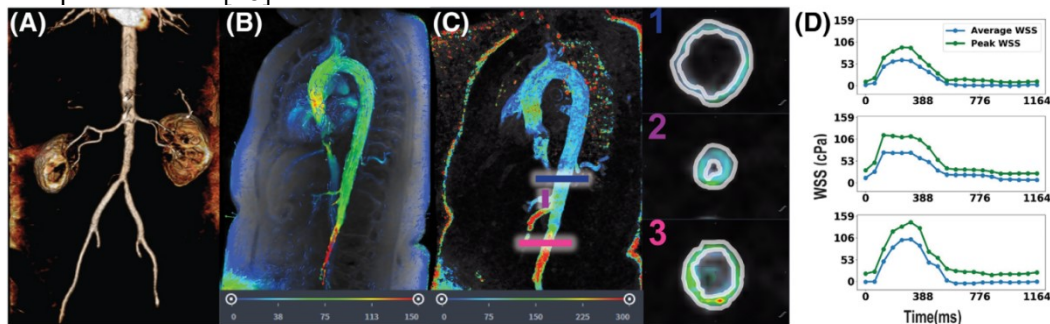
Výsledky

Pro příklad u prvního subjektu 4D Flow MRI ukazuje lokálně zvýšenou rychlost tekutiny u infrarenální břišní aorty (Obrázek č. 26). Je možné vidět zvýšenou průměrnou WSS během systoly (103 cPa) v místě patologické stenózy. Dále pak lze vidět WSS během systoly v distální sestupné hrudní aortě (62 cPa) (Obrázek č. 26C a D). Kromě toho je zvýšená WSS přítomna v břišních a nadřazených mezenterických tepnách; průměrný WSS během vrcholového systolu v břišních tepnách je 74 cPa (Obrázek č. 26D).

V normálních segmentech aorty se měření WSS jeví jako interně konzistentní. Průměrný WSS během systoly v normálních segmentech aorty se pohyboval od 49 do 65 cPa, Tyto hodnoty jsou podobné jako u dříve uváděných hodnot získaných jinými přístupy. [8,10,14,16,22]

Při porovnání s referenční metodou bylo zjištěno, že výsledky byly mírně korelované (Pearsonův test $r = 52$, $p = 4,4 \cdot 10^{-36}$) a nebyly statisticky odlišné (párový t-test $P = 0.23$, 510 párů pozorování).

Metoda prokazuje dobrou viditelnost WSS skrz aortu v každé srdeční fázi. Kromě toho jsou snadno viditelné regiony místně odlišných WSS; oblasti stenózy jsou zvýrazněny (vysoký WSS), zatímco oblasti aneurysma jsou potlačeny (nízký WSS). Po lokalizaci lézí, které jsou předmětem zájmu, lze proces vykreslit v průběhu času.[18]



Obrázek č. 26 MRA (A); 4D FlowMRI vizualizace, jednotky cm / s (B); vizualizace WSS, jednotky cPa, jednotlivé ROI jsou barevně označeny a vypočteny (C); kvantifikace WSS pro každou ROI (bílé obrysy) (D). (C): (1) distální sestupná hrudní aorta, (2) celiakální tepna, (3) intrarenální břišní aorta.[18]

2.7 Metoda dvoufázové aktivní kontury pro poloautomatickou segmentaci srdce a cév z MRI snímků pro 3D vizualizaci

Metoda kombinuje dva přístupy k segmentaci aktivních kontur, známou jako balóny (balloons) a had (snake) z 2D MR snímků. Díky tomu je tato metoda přesná a nezávislá. Byla představena nová anti-smyčková funkce ke zlepšení segmentace velmi složitých tvarů, např. levé komory a papilárních svalů. Tato metoda byla použita pro segmentaci všech velkých struktur srdce a výsledky byly použity pro 3D vizualizaci.

Hlavním problémem vizualizace srdce je transformace řezu do 3D modelu. Takovýto model obsahuje plochy jednotlivých orgánů jako například povrch srdce nebo cév. Segmentace je tedy prvním krokem pro vygenerování modelu. Při segmentaci by se měly automaticky najít hranice mezi regiony které zastupují povrch orgánu. Toto je umožněno pomocí trojúhelníkové sítě spolu s dalšími vlastnostmi snímků jako osvětlení a vlastnosti povrchu (textura, stínování).

Segmentace je nejnáročnějším procesem při vizualizaci. Hlavními aspekty ovlivňující rychlost a kvalitu segmentace je převážně počet snímků a kvalita obrazu. Celkové 3D vyšetření srdce se skládá z přibližně 70 snímků a každý z nich musí být segmentován.

Segmentace je rozdělena do dvou kroků: fáze ballonos, která slouží pro detekci přibližného místa obrysu a fáze snake pro jemné doladění modelu získaného předchozí fází. Papilární svaly byly zahrnuty do stěny LV.

Metody

Snake funkce je energií minimalizující metoda vedená vnějšími omezovacími silami a vlivy obrazových sil, které ji přitahují k prvkům, jako jsou čáry a hrany. Energie této funkce obsahuje tři termíny odpovědné za různé druhy energie:

$$E_s = \int_0^1 (E_{ext} + E_{im} + E_{in}) ds \quad (20)$$

kde E_{ext} je většinou spojena s počáteční polohou snake funkce, která způsobuje pohyb obrysových bodů směrem do okolí. E_{im} představuje vliv okrajů obrazu, který přitahuje konturové body. Lokální minimum energie funkce snake lze interpretovat jako rovnováhu sil (rovnice (21)) působící na vrchol. Kromě vnitřní síly (f_{in}) je možné definovat všechny ostatní síly bez zohlednění energetických podmínek.

$$\vec{f}_s = \vec{f}_{ext} + \vec{f}_{im} + \vec{f}_{in} \quad (21)$$

Proto může být pro výpočet použit dynamický model pro nalezení rovnováhy. Model popisuje pohyby nulové hmoty pod vlivem síly f_s . $1/\lambda$ je použito jako koeficient viskozity. Diskrétní forma iterativního procesu použitého v metodě vypadá takto:

$$\frac{1}{\lambda} \frac{d\vec{v}_t}{dt} = \vec{f}_s \quad (22)$$

Metoda Balloons funguje na principu interních a externích sil, které tlačí křivku do prostoru, jako když se nafukuje balonek. Rovnice 20 a 21 mohou být také použity pro definici Balloons modelu.

Metoda balloons

Počáteční malá kontura obsahuje několik vrcholů, které může manuálně rozmístit uživatel, v některých případech jsou rozmístěny automaticky programem. V případě že intenzita snímků není homogenní může segmentace být značně ovlivněna počátečním rozmístěním kontury. Pohyb vrcholů lze definovat touto rovnicí:


$$\vec{v}(l, t + 1) = \vec{v}(l, t) + \lambda \Delta t n(l, t) * \left[p I(\vec{v}(l, t)) - q \Delta I \vec{v}(l, t) * \vec{n}(l, t) + f_{in}(l, t) \right] \quad (23)$$

kde n je normální vektor vrcholu. Tento vektor je počítán jako střední hodnota dvou normálních vektorů segmentu, kterým vrcholy náleží. $\Delta I(v(i))$ je gradient obrazu pro bod $v(i)$. A $I(v(i))$ je intenzita obrazu. Je nutné, aby koeficienty p a q byly kladné. Gradient snímku a jeho intenzita vztahují rovnici k obrazovým informacím. Intenzita obrazu vkládá energii do aktivního obrysu (jedná se o dříve popsanou nafukovací sílu), zatímco gradient obrazu zastavuje obrys na obrazových prvcích, jako jsou čáry nebo hrany. Algoritmus se zastaví v případě, že se podmínky dostanou do rovnovážného stavu.


Anti-smyčkový vlastnosti a segmentace papilárních svalů

Aby nedocházelo k vytvoření obrazu z více smyček je potřeba aby velikost mezi vrcholy kontury byla poměrně velká (přibližně 5 pixelů na snímku s rozlišením 128 x 128 pixelů). Tento přístup je vhodný pro jednoduché segmenty. U složitějších segmentu by měla být vzdálenost mezi vrcholy menší (přibližně 1 pixel). Smyčky kontury začíná vytvořením malé smyčky, která roste s každou iterací. Jednotlivé


vrcholy kontury tvoří dva průsečíky konturových úseků. Tento bod rozděluje obrys na dvě části. V případě, že je část kratší, jedná se tedy o nepravidelnou konturu, tedy smyčku a ta je následně odstraněna. Na Obrázek č. 27 je znázorněn počet obrysových bodů v každé iteraci. Nicméně pro segmentaci papilárních svalů je toto nevhodné, a to z důvodu, že drobné smyčky mají právě velikost papilárních svalů. Proto jsou drobné smyčky převedeny na podobrys, uložený jako nová oblast, která bude následně segmentována. Na Obrázek č. 28 je možné vidět opět počet iterací funkce balloons, při poklesu na konci došlo k převedení smyček na podobrys a proto dochází k poklesu bodů. Na obr je pak vidět rozdíl před a po použití anti-smyčková funkce.



Obrázek č. 27 Počet bodů (vrcholů) v po sobě jdoucích iteracích balloon algoritmu



Obrázek č. 28 Počet bodů (vrcholů) v procesu segmentace papilárních svalů



Obrázek č. 29 rozdíl snímku levé komory s konturou tvořící smyčky (vlevo) a po použité anti-smyčková funkce

Metoda snake

Tato metoda se aplikuje po ukončení algoritmu balloons. Vrcholy se umístí do oblastí s významnými hodnotami gradientu. Následně dochází ke změně počtu vrcholů s tím, že se zachovává stejná vzdálenost mezi po sobě jdoucími vrcholy. I zde se používá ani-smýčkový algoritmus, ale riziko chyby je daleko menší než u metody balloons. Hlavní změnou v porovnání s metodou balloons je rovnice určující pohyb vrcholů:

$$\overrightarrow{v(l, t + 1)} = \overrightarrow{v(l, t)} + \lambda \Delta t \overrightarrow{n(l, t)} * \left\{ f \left[\overrightarrow{\nabla I(\overrightarrow{v(l)})} * \overrightarrow{n(l)} \right] + f_{in}(l) \right\} \quad (24)$$

V závislosti na pozitivní nebo negativní hodnotě $f + f_{in}$ se vrcholy kontury pohybují dopředu nebo dozadu podél svých normálních vektorů n . V této rovnici funkce f hledá vektor n pro maximální hodnotu mezi gradientem a vektorem n . Intenzita obrazu se počítá pomocí bilineární interpolace. Pokud je maximální gradient nalezen na vnější straně kontury, funkce f získá kladnou hodnotu a vrchol se posune směrem k nalezenému maximu. V případě, že je gradient nalezen na vnitřní straně bude postup opačný. Vrcholy tedy oscilují v blízkosti nejostřejší hrany. Tedy tuto metodu nelze spustit ze středu struktury, ale pouze v blízkosti jejího okraje. Iterační proces musí být po určitém času zastaven (v tomto případě se jednalo o 10 iterací). V případě, že se funkce f nastaví na nulu může algoritmu sloužit pro vyhlazení kontury.

Sledování aorty

Tento proces vyžaduje inicializaci pouze v jednom řezu, v ostatních se již automaticky vyhledá počáteční bod a dojde k segmentaci. Pro zjednodušení a odstranění nutnosti zásahu uživatele byla implementována automatická inicializace počátečního bodu

Byl zavedeny následující vlastnosti metody: 1) počáteční bod v následujícím řezu je určen jako průměrná poloha všech vrcholů v řezu předchozím, 2) parametr spojený s intenzitou pixelu je upraven pro každý řez. Tím se dosáhne že produkt p a a_v jsou konstantní. Kde p je parametr funkce balloons a a_v průměrná hodnota pixelu vypočítaná pro okolí počátečního bodu, 3) předpokládá se maximální počet iterací, který je přijatelný pro funkci balloons. Pokud kontura překročí toto číslo, její průměrná hodnota nebude použita jako počáteční bod v následujícím řezu.

Výsledky

Čas potřebný pro segmentaci se pohyboval kolem 3 hodin (5 v případě segmentace malých struktur) Ve srovnání s manuální segmentací se čas zkrátil až pětikrát. Automatická segmentace mohla být použita pro 60-80 % případů kde uživatel nastavil pouze počáteční bod. Tato metoda byla shledána jako vhodná pro malé struktury a struktury ležící rovnoběžně se skenovací rovinou. Pro segmentaci bylo použito 40-70 iterací fáze balloons a 20 iterací fáze hada. Stejný postup lze použít pro segmentaci aorty, levé komory a dalších oblastí bez změny parametru. [14]

2.8 3D metoda lokálního aktivního obrysu založená na 3D Hermite s eliptickými omezeními tvaru pro segmentaci srdečních MR a CT objemů

Tato práce se zabývá novou 3D hierarchickou metodu víceúrovňové segmentace založenou na modelu aktivních konturách (AC) a Hermitovy transformace (HT) pro analýzu LV pomocí CMRI výpočetní tomografie (CT) z pohledu krátké osy. Pro vyhodnocení se používají hranice endokardu a

epikardu. Segmentace endokardu je řízena pomocí eliptických tvarových omezení. Bylo navrženo inicializační schéma založené na algoritmu fuzzy C-mean a matematické morfologii. Výkon algoritmu byl vyhodnocen pomocí srdečních objemů z pohledu krátké osy.

V této práci je navržen nový 3D model AC zabudovaný do HT prostoru. Prvky, jako jsou intenzity, hrany a geometrická omezení, jsou kombinovány pomocí hierarchického víceúrovňového schématu. Intenzita a mezní informace se počítají přímo z koeficientů HT, zatímco omezení založená na tvaru jsou založena na vlastnostech AC.

Statistické tvarové modely, jako jsou ASM (modely aktivních tvarů) a AAM (modely aktivního vzhledu), používají sadu vzorových tvarů k trénování statistického modelu, který se následně používá pro segmentaci nových dat. Hans van Assen a kol. [3] kombinoval 3D ASM s algoritmem C-means pro segmentaci LV z MR snímků. Pomocí této metody lze segmentovat data s nedostatkem informací. Ecabert a kol. [17] vyvinuli přístup k extrakci čtyř dutin srdce, myokardu a velkých cév pomocí CT. Metoda používá parametrický model založený na ASM.

3D Hermiteova transformace (HT)

Cílem 3D HT je promítnout vstupní objem na prostor Hermitových polynomů, aby bylo možné extrahovat relevantní informace [28]. Nechť $f(x, y, z)$ je 3D vstupní funkce, její 3D HT se počítá takto:

$$L_{n-m,m-l,l}(p, q, r) = \int_{-\infty}^{\infty} f(x, y, z) V^2(x - p, y - q, z - r) * G_{n-m,m-l,l}(x - p, y - q, z - r) dx dy dz \quad (25)$$

kde $L_{n-m,m-l,l}(p, q, r)$ jsou 3D kartézské koeficienty Hermiteovy transformace, $V(x, y, z)$ je izotropní 3D gaussovské okno se standardní odchylkou σ ,


$G_{n-m,m-l,l} = W H_{n-m}\left(\frac{x}{\sigma}\right) H_{m-l}\left(\frac{y}{\sigma}\right) H_l\left(\frac{z}{\sigma}\right)$ odpovídá normalizovaným 3D Hermite polynomům, které jsou ortogonální vzhledem k $V^2(x, y, z)$ a $W = \frac{1}{\sqrt{2^n(n-m)!(m-l)!l!}}$.

Koeficienty byly počítány takto $n = 0, 1, \dots, N$; $m = 0, 1, \dots, n$ a $l = 0, 1, \dots, m$ kde n je pořadí transformace.

Implementaci 3D HT lze provést konvolucí vstupní funkce se sadou filtrů Hermite definovaných jako:

$$D_{n-m,m-l,l}(x, y, z) = V^2(x, y, z) G_{n-m,m-l,l}(x, y, z) = W \frac{d^{n-m}}{d\left(\frac{x}{\sigma}\right)^{n-m}} \frac{d^{m-l}}{d\left(\frac{y}{\sigma}\right)^{m-l}} \frac{d^l}{d\left(\frac{z}{\sigma}\right)^l} V^2(x, y, z) \quad (26)$$

a následně převzorkování v pozicích (p, q, r) . Pro zjednodušení byla použita podvzorkovací proměnná $T = p = q = r$. Obrázek č. 30a ilustruje příklad 3D HT. Obrázek č. 30b Chyba! Nenalezen zdroj odkazů.b zobrazuje řízené Hermiteovy koeficienty získané z kartézských koeficientů.



Obrázek č. 30 Koeficienty 3D HT aplikované na srdeční objem MR. Řezy ukazují střed srdce. (a) kartézské koeficienty. (b) řízené koeficienty.

Navrhovaná Inicializace

Při použití lokálních modelů AC [25] je třeba pečlivě vybrat počáteční tvar. Za tímto účelem byla navrženo nové poloautomatické inicializační schéma, které kombinuje fuzzy metodu C [12] s morfologickými operátory. Nejprve jsou ručně definovány limity pro základnu a vrchol LV. Histogram obrazu odpovídající středu LV se zpracuje tak, aby se získaly počáteční průměrné hodnoty pro LV dutinu a myokard. Algoritmus fuzzy C-means následně rozdělí celkový objem do tří tříd: pozadí, myokard a podobné tkáně, LV a podobné tkáně. Jakmile je vstupní objem zpracován pomocí fuzzy C-algoritmu, musí se vypočítat počáteční povrchy pro endokard a epikard.

Navrhovaný AC model

AC model se skládá z dvou regionů (lokální a globální), termínu založeného na okrajích a dvou geometrických termínů. Byla navržena energetická funkce pro rozdělení endokardu a epikardu, která je definovaná takto:

$$E = \lambda_1 E_L + \lambda_2 E_G + \lambda_3 E_B + \lambda_4 E_S + \lambda_5 E_R, \quad (27)$$

kde E_L a E_G jsou lokální a globální energetické funkce E_B je energie založená na hranicích, E_S je omezení tvaru a E_R je termín regularizace. Energie E_S má za úkol zastavení pohybu kontury při dosažení hrany. Jako počáteční tvar se využívá elipsa, a to z důvodu největší podobnosti s LV. Tvarová energie udržuje pravidelnou deformaci AC během expanze. Protože není nezávislá na obrazových prvcích, nemůže vést konturu směrem k hraničním objektu. Pro tento energetický termín je použita dvojité konfigurace: této energii je na začátku vývoje přiřazena malá váha pro určitý počet iterací. Tato váha se následně zvyšuje. Při této konfiguraci je AC volně deformována během prvních iterací a poté upravena tak, aby udržovala geometrický tvar definovaný pro zpracovaný objekt.

Výsledky

Pro vyhodnocení bylo použito několik metrik: vzdálenost od bodu k křivce (PCD), vzdálenost od bodu k povrchu (PSD), upravená Hausdorffova vzdálenost (MHD) [16] a koeficient podobnosti kostek (DSC). K ověření byly použity dvě sady srdečních objemů získaných pomocí MR a jedna sada pomocí CT. První MR soubor dat se skládá z 15 pacientů, pro každého pacienta bylo nasnímáno 20 srdečních fází, vybraných z databáze MICCAI [46]. Snímky byly získány v pohledu krátké osy. Druhá sada dat

MR se skládá z 15 pacientů vybraných z databáze [2]. Snímky byly také získány skenerem GE Genesis Signa MR. Pro každého pacienta bylo snímáno 20 srdečních fází. Sada s CT daty také obsahovala 15 pacientů.


Tabulka 9 DSC získané segmentací výsledků 4 metod, včetně navržené metody. Testování proběhlo na MR datasetu 1

	Endokard	Epikard
Metoda 1	$0,890 \pm 0,030$	$0,940 \pm 0,020$
Metoda 2	$0,869 \pm 0,042$	$0,921 \pm 0,020$
Metoda 3	$0,886 \pm 0,039$	$0,928 \pm 0,016$
Použitá metoda	$0,910 \pm 0,018$	$0,939 \pm 0,009$

Výsledky s použitím první sady dat MR pomocí metriky DSC jsou uvedeny v Tabulka 10. DSC byl vypočítán pro všechny řezy ve fázi ED a ES pro každého pacienta. Výsledky jsou nakonec zprůměrovány pro všechny pacienty a prezentovány samostatně pro endokard a epikard. Je třeba poznamenat, že navržená metoda dosáhla lepších výsledků, než jaké byly uvedeny ve nejmodernějších studiích.

Příklad výsledků navrhované metody segmentace je zobrazena na Obrázek č. 31. Je možné vidět objemové řezy vybrané z každého MR datasetu. LV je vizualizována na základně, středu a vrcholu srdce. Červený obrys značí ruční anotaci a zelený obrys segmentaci získanou navrhovaným algoritmem.

Na rozdíl od MR snímků je u CT snímků nižší kontrast a hranice, které oddělují srdeční struktury, je obtížnější identifikovat. Nicméně CT snímky jsou získány z axiálního pohledu. Tedy k zajištění pohledu krátké osy, použitého pro vyhodnocení LV, je nutný rotační proces. Získané PCD, MHD a PSD jsou uvedeny v Tabulka 10 pro ED a ES fázi. [15]



Obrázek č. 31 Výsledky pro LV, základna (levý sloupec), střed (prostřední sloupec), vrchol (pravý sloupec) [15]

Tabulka 10 Průměrné PCD a MHD [mm]

	PCD	MHD	PSD
Fáze ED	$0,9387 \pm 0,2507$	$1,2038 \pm 0,7171$	$0,8035 \pm 0,3179$
Fáze ES	$0,9718 \pm 0,2133$	$1,4785 \pm 1,0679$	$0,7848 \pm 0,2723$

2.9 Nepodřízená segmentace myokardu pro srdeční BOLD


Současný pokrok v metodách magnetické rezonance srdce (CMR), jako je MRI závislá na hladině krevního kyslíku v srdeční fázi (CP-BOLD), otevírá možnosti přímého a rychlého vyšetření ischemie [1]. Při jediné akvizici poskytuje CP-BOLD BOLD kontrast i informace o funkci myokardu [2]. Nicméně vzorce intenzity se mění v čase i v prostoru. Tyto vzorce jsou však jemné a změny, ke kterým dochází v důsledku nemoci, nelze přímo vizualizovat. Jejich identifikace vyžaduje významné následné zpracování, včetně segmentace a registrace myokardu [5], před samotnou diagnostikou. V současné době vyžaduje segmentace myokardu CP-BOLD zdoluhavý manuální zásah. Proto byla vyvinuta segmentační metoda pro MRI CP-BOLD, která je plně automatizovaná s cílem věrně zachovat klíčové vzorce nezbytné pro diagnostiku.

Metodika

Metoda pracuje na tzv. slovníkovém přístupu zavedeném v [9] který používá společný vzhledu a model pohybu zavedeného v [10]. Aby došlo ke zvýšení odolnosti efektu BOLD, byl představen krok předzpracování, jehož cílem je „vyhladit“ změny časové intenzity založené na celkové variaci a lokalizaci myokardu. Předpokladem této metody, je rozdílnost pohybových vzorců myokardu od pohybových vzorců okolních tkání a orgánů. Na závěr se využívá prostorových regularizací pomocí Markovova náhodného pole (MRF), díky kterému se provede finální segmentace.

Předzpracování

Využívá techniku filtrování založená na celkové variantě k vyhlazení snímků a snížení efektu BOLD. K tomuto byla použita Lagrangianovu metoda [37] pro vyřešení BOLD nehomogenity v čase i prostoru. Poté je použit postup založený na víceúrovňovém prahování histogramu k nalezení středu levé komory (LV). Využívá Otsu metoda [40] pro každý snímek v cyklu. Pomocí této metody dojde k nalezení 4 částí: Krevní pool, malý prostor mezi poelem a myokardem, myokard samotný a okolí. Následně pomocí dvou nejjasnějších částí (nejvíce podobných kružnici) dojde k nalezení středu krevního poolu. Nakonec s pomocí transformace vzdálenosti se identifikuje popředí a pozadí, z nichž se odebírají vzorky. Jak je ukázáno na Obrázek č. 32 **Chyba! Nenalezen zdroj odkazů..** Tyto vzorky pak složí pro tzv. Učení slovníků.



Obrázek č. 32 Extrakce pozadí a regionů myokardu. LV krevní pool (vlevo); Transformace vzdálenosti od hranice krevního poolu LV (uprostřed); Základní třídy a popřední třídy (vpravo).

Učení slovníků

Učení slovníků se provádí na základě třídy, které společně modelují vzhled a pohyb. Očekává se, že různé pohybové vzorce myokardu a pozadí a jejich řídká reprezentace pohybu vedou definici vhodných lineárních podprostorů, aby zachytily proměnlivosti dat. Na základě získaných dat se vytvoří dvě matice, jedna pro popředí snímku a druhá pro jeho pozadí. Matice pak slouží k naučení slovníků. Nicméně aby bylo dosaženo diskriminační inicializace je potřeba ignorovat vysoce korelované údaje. Proto se používá „Gramova filtrace uvnitř třídy“. Po provedení filtrace dojde k omezení koeficientů o 10 %. Tím se zaručí větší rozdílnost mezi jednotlivými třídami.

Vyhlazení na bázi MRF

Využívá se MRF strategie pro posílení prostorové regularizace. MRF se aplikuje pro každý snímek v databázi. Tím dojde k zajištění lokální hladkosti klasifikace. Pro získání konečné segmentace je nutná minimalizace MRF energetické funkce:

$$E_{MRF}(I_t) = \sum_{p \in I_t} \left(V_p(I_p) + \lambda V_{pq}(I_p, I_q) \right), \quad (28)$$

kde $V_p(.)$ odpovídá unárnímu potenciálu představujícím datový termín pro uzel p a $V_{pq}(.)$ odpovídá párovému potenciálu představujícím termín plynulosti pro pixely v uzlech p a q v okolí N na obrázku I_t . Datový termín měří nesoulad mezi předchozími a pozorovanými údaji, který je založen na slovnících. Parametr λ řídí kompromis mezi hladkostí a datovým termínem, který řídí finální segmentaci. Termín plynulosti penalizuje diskontinuity v okolí N . Celková energie se počítá pomocí zbytků pro možné štítky RF v popředí a pozadí RB.

Výsledky

Datová sada se skládá ze stejných 10 subjektů zobrazených ve čtyřech různých nastaveních. Byly získány 2D obrazy z pohledu krátké osy celého srdečního cyklu, a to jak u zdravého srdce, tak po ischemii (způsobené stenózou LAD). Snímky byly získány s prostorovým rozlišením 1,25 mm 1,25. Pro vyhodnocení výkonu byly použity tři metriky, první dvě se používají při hodnocení segmentace [48]. Zjišťovala se míra překrytí kostkami (DOM), která je definována mezi dvěma regiony A a B jako:

$$S(A, B) = \frac{2||A \cap B||}{||A|| + ||B||}, \quad (29)$$

Hausdorffova vzdálenost mezi dvěma konturami C^A a C^B pro zjištění shody základní pravdy s výsledky algoritmu.


$$HD(C^A, C^B) = \max \left\{ \max_{a \in C^A} \min_{b \in C^B} d(a, b), \min_{b \in C^B} \max_{a \in C^A} d(a, b) \right\} \quad (30)$$

kde d prezentuje vzdálenost bodu $a \in C^A$ a $b \in C^B$.

Na závěr je potřeba vyhodnotit, jak chyby v segmentaci ovlivňují odpověď BOLD (a její vzorce), používá se kosinová podobnost k vyhodnocení shody mezi dvěma signály intenzity S^A ; a S^B .

$$CS = \frac{S^A * S^B}{|S^A| \cap |S^B|} * 100 [\%], \quad (31)$$

U standardních CMRI většina algoritmů funguje dostatečně dobře, ale přítomnost ischemie mírně snižuje výkon. Pokud je však přítomen kontrast BOLD, některé přístupy, které nebyly navrženy pro zpracování kontrastu BOLD, ztrácejí výkon. Konkrétně se ukázalo, že metody založené na atlasu, ACRF a TACRF fungují lépe ve standardním CMRI ve srovnání s CP-BOLD. Mezi metodami založenými na slovníku funguje DDLS ve standardním CMRI dobře, ale v CP-BOLD MR nedosahuje dobré výkonnosti. Vizualní porovnání Standardního CMRI a CP-BOLD MR je na Obrázek č. 33.



Obrázek č. 33 Výsledek segmentace (červený) navrhované metody jak pro CP-BOLD MR, tak pro standardní CMRI ve základní stavu a ischemii pro koncovou diastolickou (ED) a koncovou systolickou (ES) fázi překrývající se s odpovídajícími konturami ruční segmentace (zelené), které určili odborníci

V případě Hausdorffových vzdáleností se největší hodnoty nacházejí v nižší oblasti srdce hlavně kvůli přítomnosti jater. Na základě porovnání je možné vidět, že v přítomnosti ischemie dochází ke stabilitě metody. Míra překrytí kostkami se počítá pro 6 oblastí myokardu. Obecně je algoritmus odolný vůči regionálním složitostem myokardu. Ischemie mírně ovlivňuje výkonnost zejména v regionech, které jsou pod vlivem stenózy LAD.


Navrhovaná metoda překonává jiné metody segmentace, a to platí i v případě, že je přítomno onemocnění. To platí také kvantitativně při porovnání s metodou založenou na atlasu [6] při porovnání s použitím metriky podobnosti cosinů. Je zřejmé, že malé chyby (dokonce 5 až 10 pixelů) v segmentaci směrem k oblastem hyperintense (krevní pool) nebo hypointense (rozhraní plic / jater), mají závažný efekt na zachování signálu BOLD. [16]


3. Struktura obrazových dat

Pro testování robustnosti programu a segmentace byla použita databáze Sunnybrook Cardiac Data (SCD). Tato databáze obsahuje snímky srdce získané pomocí magnetické rezonance od 45 pacientů napříč celým srdcem. Snímky jsou získány z pohledu krátké osy, dlouhé osy, čtyř a dvou komor. Pro segmentaci byly použity snímky z pohledu krátké osy. Všechny testované snímky mají rozlišení 256x256px. Dále tato databáze obsahuje informace o manuálních konturách provedené expertem v rámci 2009 LV Segmentation Challenge. V databázi nalezneme snímky pacientů jak se zdravým srdcem (9 pacientů) tak s různými patologiemi a to: hypertrofie (12 pacientů), srdeční selhání (12 pacientů) s infarktem a srdeční selhání bez infarktu (12 pacientů). Datová sada obsahuje snímky 13 žen a 32 mužů ve věku od 23 do 88 let. Snímky jsou ve formátu DICOM. Pro následné zpracování v prostředí matlab byly převedeny do bezztrátového formátu .png pomocí free softwaru Micro dicom. Snímky pořízené z pohledu krátké osy jsou získány v tzv. MOLLI sekvencích. Každá sekvence obsahuje 20 snímků jednoho řezu napříč ED (koncová diastolická) a ES (koncová systolická) fází.


3.1 Selhání srdce s infarktem a bez infarktu


Ukázku sekvence pro pacienty po selhání srdce s infarktem a bez infarktu na Obrázek č. 34 a 35. Příčinou selhání srdce bývá akutní insuficience jeho následkem je ve většině případů dilatace komor a snížení tloušťky svaloviny. Nastává snížení srdečního výdeje a snížení míry kontrakce srdečního svalu. Na snímcích je možné vidět nedostatečnou kontrakci.[22]





Obrázek č. 34 Ukázka MOLLI sekvence pacienta po selhání srdce s infarktem







Obrázek č. 35 Ukázka MOLLI sekvence pacienta po selhání srdce bez infarktu

3.2 Hypertrofie

Hypertrofie je následkem kompenzace chronické insuficience. Dochází k nárůstu velikosti buněk myokardu, tedy zvětšení srdečního svalu a jeho hmotnosti. Může dojít ke zmenšení objemu srdečních komor a zvýšení nároku srdce na kyslík. Zároveň dochází k zvýšení kontrakce srdce a namáhání celého kardiovaskulárního systému. [22] Příklady snímků pacienta s hypertrofií je možné vidět na Obrázek č. 36






Obrázek č. 36 Ukázka MOLLI sekvence pacienta s hypertrofií

4. Návrh matematického modelu pro detekci a analýzu myokardu na MR snímcích

Cílem diplomové práce je návrh algoritmu pro automatizovanou detekci a analýzu srdečních struktur z MOLLI sekvencí. Jak již bylo zmíněno v kapitole 3 pro tuto diplomovou práci byly zvoleny snímky fokusované na levou komoru z pohledu krátké osy. Levá komora je nejvíce namáhanou částí kardiovaskulárního systému. Při její analýze je možné odhalit četné srdeční problémy. Z pohledu krátké osy je možné měřit jak parametry její dutiny, tak i tloušťku její svaloviny.

MOLLI sekvence zobrazují levou komoru napříč fázemi, a to při koncové systolické a koncové diastolické fázi. Tyto sekvence zachytí jednotlivé fáze v průběhu několika srdečních cyklů. Srdce je ovšem v neustálém pohybu, a proto dochází k rozdílnému umístění levé komory na jednotlivých snímcích. Pro objektivní analýzu je potřeba nalézt průměrný obraz získaný z MOLLI sekvencí. Pro nalezení průměrného obrazu je potřeba snímky zarovnat na základě referenčního bodu, který činní těžiště komory.



Obrázek č. 37 Zobrazení srdce z pohledu krátké osy, RV – Right Ventricle (pravá komora), LV - left Ventricle (Levá komora) [21]

Diagram níže zobrazuje základní kroky algoritmu. Algoritmus je navržen jako automatizovaný, tedy je potřeba zásahu uživatele pro ovládání programu a vložení počáteční kontury, aby bylo možné úspěšně segmentovat strukturu napříč všemi snímky v sekvenci. Načtené snímky je nutno nejprve předzpracovat a vybrat oblast zájmu pro snížení výpočetních nároků a usnadnění segmentace. Tím se zajistí zvýraznění snímku a lepší možnost pro aplikaci inicializační kontury. Je potřeba správně nastavit parametry aktivní kontury jak pro separaci levé komory, tak i pro její svalovinu. Nejprve se provede separace LV a následná binarizace. Dále je potřeba vložit novou konturu s novými parametry pro segmentaci svaloviny LV. Binarizace je provedena tak, že se hodnoty uvnitř kontury nastaví na jedničku a hodnoty vně na nulu. Konečným krokem je měření extrahovaných parametrů jako obsahu dutiny v řezu, její délku a šířku a tloušťku srdeční svaloviny.



Obrázek č. 38 Vývojový diagram segmentace myokardu

4.1 Načtení dat

Prvním krokem na je načtení sekvence snímků, tedy testované MOLLI sekvence. Ta, jak již bylo zmíněno výše se skládá z dvaceti snímků. Při načtení dojde k převedení snímku do šedé škály na základě následujícího algoritmu:

$$\text{Monochromatický obraz} = 0.2989 \cdot R + 0.5870 \cdot G + 0.1140 \cdot B, \quad (32)$$


proměnné R, G, B jsou hodnoty jednotlivých pixelů červené, zelené a modré chromatické složky. Takto vytvořené 2D snímky se následně uloží do matice za sebou, tedy každá souřadnice z této matice reprezentuje jeden snímek.

Výběr ROI probíhá v cyklu for. Nejprve se vybere oblast zájmu z prvního snímku a parametry se uloží do proměnné tyto parametry se pak aplikují na každý ze snímků. Výsledkem je opět trojrozměrná matice všech oříznutých snímků.

4.2 Předzpracování


Předzpracování je rozdílné pro v případě, že je potřeba segmentovat LV nebo její svalovinu. Samotné předzpracování se provádí v několika krocích. U segmentace LV se provede jasové transformace, kdy dojde k rozprostření histogramu původního snímku na celý rozsah šedé škály a tím se zajistí zvýšení jasu u světlých částí a potlačení tmavých. Dalším krokem je aplikace mediánového filtru. Jedná se o jednotkovou matici velikosti 3×3 , která postupně klouže po snímku pixel po pixelu a počítá mediány dané oblasti. Ty jsou následně uloženy jako nový obrazový bod.

Princip předzpracování pro segmentaci svaloviny LV je velmi podobný. Ačkoliv se liší v parametrech. Je nutno zajistit potlačení světlých složek obrazu a zesvětlení tmavých. Toto je zajištěno správnou volbou parametrů. Tyto parametry se pohybují v rozmezí od 0 do 1 a reprezentují 0-100% intenzity šedé škály. Obrázek č. 39 zobrazuje graf změny jasu při segmentaci LV svaloviny. V podstatě dojde ke změně nulových složek na 100 % a potlačení zbylých 80 %.




Obrázek č. 39 Graf jasové transformace u segmentace LV svaloviny

Následně je také aplikovaný mediánový filtr, tentokrát velikosti 6×6 a to z důvodu zvýšení jednotnosti jasu srdeční svaloviny, a tedy zajištění kvalitnější segmentace.



Obrázek č. 40 Ukázka předpracování obrazu pro segmentaci LV: z leva doprava – načtený snímek, ROI, snímek po aplikaci jasové transformace, snímek po aplikaci mediánového filtru. Nahoře pacient po selhání srdce s infarktem, dole pacient s hypertrofií



Obrázek č. 41 výsledek předzpracování pro segmentaci srdeční svaloviny. Nahoře pacient po selhání srdce s infarktem, dole pacient s hypertrofií

5. Návrh a implementace algoritmu pro detekci srdečních struktur

Na základě studie metod používaných pro detekci srdečních struktur patří mezi nejčastěji používané metody tzv. metody aktivních kontur. Jedná se o deformovatelné modely, kdy se vložená iniciační kontura doformuje na základě vlastností v obraze. Tyto vlastnosti mohou být dány hranami v obraze nebo statickým rozložením pixelů. V podstatě na základě těchto vlastností dochází při každé iteraci, kroku, k výpočtu vnitřní (uvnitř kontury) a vnější (vně kontury) energie. Tato energie následně určuje deformaci kontury.

V této práci je využívána metoda lokální Gaussovské distribuce. Jedná se o metodu využívající lokální distribuci intenzit v obraze. Důvodem volby této metody je menší náchylnost na šum v obraze a zajištění kvalitnější segmentace u snímků s jasovou nehomogenitou.

5.1 Metoda založena na lokální Gaussovské distribuci[23]

Jak již bylo zmíněno metoda pracuje s lokálním rozložením intenzit v obraze. Pro efektivní využití informací ohledně místních intenzitách, je potřeba charakterizovat rozložení místních intenzit prostřednictvím sousedství. Tedy pro každý bod x v obrazové doméně Ω je uvažováno malé okolí o poloměru ρ , které je definováno jako $\theta_x \triangleq \{y: |x - y| \leq \rho\}$. $\{\Omega_i\}_{i=1}^N$ definuje skupinu rozdělení kde N určuje počet regionů. Tedy dojde k rozdělení oblasti θ_x na N regionů. Segmentace této oblasti θ_x je založena na maximální empirickém poznání pravděpodobnosti neboli MAP. Představme si, že $p(y \in \Omega_i \cap \theta_x | I(y))$ je pravděpodobností podoblastí $\Omega_i \cap \theta_x$ danou hodnotami odstínu šedé $I(y)$. Na základě Bayesova pravidla platí

$$p(y \in \Omega_i \cap \theta_x | I(y)) = \frac{p(I(y) | y \in \Omega_i \cap \theta_x) p(y \in \Omega_i \cap \theta_x)}{p(I(y))}, \quad (33)$$

kde $p(I(y) | y \in \Omega_i \cap \theta_x)$ je hustota pravděpodobnosti v regionu $\Omega_i \cap \theta_x$, tedy distribuce šedé hodnoty v regionu. Pravděpodobnost $p(y \in \Omega_i \cap \theta_x)$ je pravděpodobnost rozložení regionu $\Omega_i \cap \theta_x$ napříč všemi částmi oblasti θ_x , a $p(I(y))$ je pravděpodobnost hodnot šedé, která ovšem je nezávislá na výběru regionu, a tedy je možné ji zanedbat. Vzhledem k tomu že všechny oddíly mají stejnou pravděpodobnost a za předpokladu, že pixely v každé oblasti budou nezávislé je potřeba nalézt MAP pomocí maximalizace produktů $p_{i,x}(I(y))$ napříč regiony. Při použití logaritmu lze maximalizaci převést na minimalizaci energie E_{LGD} tímto způsobem:

$$E_x^{LGD} = \sum_{i=1}^N \int_{\Omega_i \cap \theta_x} -\log p_{i,x}(I(y)) dy, \quad (34)$$

Jak již bylo zmíněna metoda se zabývá Gaussovou distribucí. Gaussovské rozdělení je ale prostorově proměnlivý parametr. Dané vzorcem:

$$p_{i,x}(I(y)) = \frac{1}{\sqrt{2\pi}\sigma_i(x)} \exp\left(-\frac{(u_i(x) - I(y))^2}{2\sigma_i(x)^2}\right), \quad (35)$$

Kde $u_i(x)$ a $\sigma_i(x)$ jsou střední intenzity a směrodatné odchylky. Vložení této váhové funkce do funkce (34) získáme následující objektivní funkci:

$$E_x^{LGDF} = \sum_{i=1}^N \int_{\Omega_i \cap \Theta_x} -\omega(x-y) \log p_{i,x}(I(y)) dy, \quad (36)$$

$\omega(x-y)$ je váhová funkce, kde $\omega(x-y) = 0$ pro $|x-y| > \rho$ a $\int_{\Theta_x} \omega(x-y) dy = 1$.

Konečným cílem je minimalizovat energii pro všechny středové body x obrazové domény Ω , což vede k definici integrální energetické funkce:

$$E^{LGDF} = \int_{\Omega} E_x^{LGDF} dx = \int_{\Omega} \left(\sum_{i=1}^N \int_{\Omega_i} -\omega(x-y) \log p_{i,x}(I(y)) dy \right) dx \quad (37)$$

Dvojitý integrál zajistí minimalizaci funkcionálu E_x^{LGDF} pro každý bod v obraze.

Obrazová doména lze být rozdělena na dvě oblasti, a to na oblast popředí a pozadí. Aplikací heaviside funkce H může být energie E_x^{LGDF} vyjádřena jako φ , u_i , a σ_i^2 .

$$\begin{aligned} E_x^{LGDF}(\varphi, u_1(x), u_2(x) \sigma_1(x)^2, \sigma_2(x)^2) \\ = - \int \omega(x-y) \log p_{1,x}(I(y)) M_1(\varphi(y)) dy \\ - \int \omega(x-y) \log p_{2,x}(I(y)) M_2(\varphi(y)) dy \end{aligned} \quad (38)$$

, kde $M_1(\varphi(y)) = H(\varphi(y))$ a $M_2(\varphi(y)) = 1 - H(\varphi(y))$. Na základě tohoto vyjádření může být energie E^{LGDF} přepsána takto:

$$\begin{aligned} E^{LGDF}(\varphi, u_1(x), u_2(x) \sigma_1(x)^2, \sigma_2(x)^2) \\ = \int_{\Omega} E_x^{LGDF}(\varphi, u_1(x), u_2(x) \sigma_1(x)^2, \sigma_2(x)^2) dx \end{aligned} \quad (39)$$

Pro přesnější výpočet zahrnující Level-set funkci a její vývoj je třeba ji regularizovat penalizací její odchylky od přiřazené funkce vzdálenosti [34], charakterizované následující funkcí:

$$P(\varphi) = \int \frac{1}{2} (|\nabla \varphi(x)| - 1)^2 dx, \quad (40)$$

Také je potřeba penalizace délky nulové hladiny pro zajištění hladkého obrysu během vývoje:

$$L(\varphi) = \int |\nabla H(\varphi(x))| dx, \quad (41)$$

výsledná energetická funkce je tedy definována jako:

$$F(\varphi, u_1, u_2, \sigma_1^2, \sigma_2^2) = E^{LGDF}(\varphi, u_1, u_2, \sigma_1^2, \sigma_2^2) + vL(\varphi) + \mu P(\varphi), \quad (42)$$

Parametry $v, \mu > 0$ jsou váhové konstanty. V praxi je Heaviside funkce aproximována vyhlazovací funkcí H_ε definovanou jako:

$$H_\varepsilon(x) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan \left(\frac{x}{\varepsilon} \right) \right], \quad (43)$$

a derivace této funkce je následná vyhlazovací funkce:

$$\delta_\varepsilon = H'_\varepsilon(x) = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + x^2}, \quad (44)$$

energetický funkcionál je pak aproximován takto:

$$F_\varepsilon(\varphi, u_1, u_2, \sigma_1^2, \sigma_2^2) = E_\varepsilon^{LGF}(\varphi, u_1, u_2, \sigma_1^2, \sigma_2^2) + vL_\varepsilon(\varphi) + \mu P_\varepsilon(\varphi), \quad (45)$$

Finálním krokem je opět minimalizace energetické funkce F_ε

$$\frac{\partial \varphi}{\partial t} = -\delta_\varepsilon(\varphi)(e_1 - e_2) + v\delta_\varepsilon(\varphi)\operatorname{div}\left(\frac{\nabla \varphi}{|\nabla \varphi|}\right) + \mu\left(\nabla^2 \varphi - \operatorname{div}\left(\frac{\nabla \varphi}{|\nabla \varphi|}\right)\right), \quad (46)$$

kde

$$e_1(x) = \int_\Omega \omega(y - x) \left[\log(\sigma_1(y)) + \frac{(u_1(y) - I(x))^2}{2\sigma_1(y)^2} \right], \quad (47)$$

a

$$e_2(x) = \int_\Omega \omega(y - x) \left[\log(\sigma_2(y)) + \frac{(u_2(y) - I(x))^2}{2\sigma_2(y)^2} \right], \quad (48)$$

Pro následující segmentaci je potřeba nejdříve správně nastavit parametry inicializační kontury. Hlavními parametry jsou následující:

- **Velikost inicializační kontury** – tento parametr má značný vliv na délku trvání segmentace a také její kvalitu. Pokud je zvolena kontura příliš malá může dojít k nedostatečné segmentaci. Pokud příliš velká může dojít k segmentování okolních struktur.
- **Sigma (σ)** - určuje velikost kernelovské funkce, čím je velikost menší tím je následná segmentace rychlejší a funkce má menší tendenci přeskakovat na okolní struktury. Vyšší hodnoty má negativní důsledek, a to v horší segmentaci z důvodu nízkého počtu okolních pixelů.
- **Doba iterace** – určuje rychlost každého kroku. Čím větší bude tím rychlejší bude segmentace, ale hrozí přeskok funkce na jiné struktury.
- **Vnitřní síla (λ_1)** – konstanta určující váhu uvnitř kontury
- **Vnější síla (λ_2)** - konstanta určující váhu vně kontury

Poměrem λ_1 a λ_2 určujeme, zda kontura bude mít tendenci se zvětšovat nebo smršťovat. Dalším důležitým parametrem je počet iterací. Množství iterací určuje počet kroků, kdy bude docházet k deformaci kontury. Velký počet může způsobit segmentaci okolních struktur, kdežto menší nedostatečnou segmentaci. Zároveň tento parametr také ovlivňuje celkovou dobu segmentace.


5.2 Segmentace srdečních struktur


Pro nalezení struktury je nejprve zapotřebí vložit inicializační konturu. Ta byla nastavena jako kruhová, aby nejlépe kopírovala tvar levé komory. Vložení počáteční kontury se provádí pomocí pohyblivého kurzoru, který definuje střed počáteční kontury. Z důvodu velké variability rozměrů srdečních komor mezi subjekty je možné měnit rozměry iniciační kontury a množství iterací.

Pro účinnou segmentaci srdečních struktur bylo potřeba správně navolit parametry aktivní kontury. Tyto parametry byly zvoleny experimentálně, na základě testování a informacím o aktivních konturách. Hlavní parametry aktivní kontury:

Tabulka 11 Parametry aktivních kontur

Parametry	Segmentace LV	Segmentace svaloviny LV
Počet iterací	160-240	110-140
Velikost iniciační kontury	1-10	18-40
Sigma (Velikost kernelu)	5	4
Doba iterace	0,04	0,03
Vnitřní síla	1,06	1,03
Vnější síla	1,01	1,18






Obrázek č. 42 Evaluace kontury postupně od shora dolů: Inicializační kontura, segmentace po 50 iteracích, 150 iteracích, 250 iteracích

Na obrázku výše můžeme vidět postupnou evaluaci kontury. Pro dvě velikostně rozdílné kontury. Vlevo je segmentováno srdce pacienta po selhání srdce s infarktem vpravo pak pacienta s hypertrofií. Pro pacienta s hypertrofií byla záměrně použita menší inicializační kontura, a to z důvodu menšího obsahu srdce v řezu při úplné kontrakci.


5.3 Binarizace a registrace obrazu

Pro zjednodušení následující práce a výpočtů je potřeba oddělit segmentovaný objekt od pozadí. Pro tento krok slouží binarizace. Ta vychází z energetické mapy kontury (Obrázek č. 43 Ukázka energetické mapy aktivní kontury segmentované levé srdeční komory), která pojednává o energetických hladinách v obraze. Studené barvy vykazují záporné hodnoty a teple barvy hodnoty kladné. Při binarizaci tedy všechny oblasti, které jsou kladné jsou nastaveny na nulu, tedy pozadí. A záporné a nulové hodnoty na hodnotu jedna. Tento krok se aplikuje na celou matici snímků a získáme opět matici tentokrát binárních kontur.



Obrázek č. 43 Ukázka energetické mapy aktivní kontury segmentované levé srdeční komory

Registrace snímků je provedena pomocí těžiště každé kontury. Princip výpočtu těžiště je znázorněn na obrázku níže:





Obrázek č. 44 Princip nalezení těžiště hledané struktury

Jakmile jsou získány informace o těžištích každé ze segmentovaných struktur je potřeba tyto struktury vystředit. První snímek je brán jako referenční. Od jeho těžiště se odečte těžiště následujícího snímku a dojde k posunutí právě o tuto vzdálenost. Tento princip se provede pro každý snímek v sekvenci vůči snímku referenčnímu.

Vzhledem k tomu že se jedná o snímky stejného řezu v různých srdečních fázích a je potřeba měřit parametry dané struktury je potřeba tyto snímky zprůměrovat. To se provede klasickým aritmetickým průměrem všech pixelů celé matice snímků.

I přes předchozí nastavení aktivních kontur může při segmentaci dojít k přeskočení aktivní kontury na okolní struktury. Tato struktura se může projevit na finálním snímku a je potřeba ji eliminovat, aby nedocházelo k chybám při měření. Eliminace je provedena pomocí mediánového filtru velikosti 6×6 , tím je zajištěno odstranění malých struktur s minimálním efektem na hrany segmentované struktury.





Obrázek č. 45 Příklad binarizovaných snímků, konkrétně pro pacienta trpícího hypertrofií




Obrázek č. 46 Zprůměrovaný snímek z předchozích binarizovaných snímků

5.4 Měření parametrů srdce

SW prostředí programu MATLAB umožňuje měření geometrických parametrů binární struktury. V této práci bylo potřeba se zaměřit na rozměry srdeční komory její délku šířku obsah. Dále pak na tloušťku srdeční svaloviny. Délka a šířka jsou vypočítány jako nejdelší a nejkratší elipsoidní vzdálenost. Obsah je pak počítán jako počet bílých pixelů struktury. Tyto hodnoty jsou ovšem v pixelech a je potřeba je přepočítat na milimetry. To bylo zajištěno vynásobením hodnotou 1.365. Tato hodnota byla získána pomocí SW MicroDicom a to jako poměr vzdálenosti a počtu pixelů, hodnota tedy udává vzdálenost na jeden pixel.

Měření svaloviny levé komory bylo prováděno pomocí pohyblivého kurzoru. Kde bylo potřeba zjistit vzdálenost mezi dvěma body. Tato vzdálenost je opět v jednotkách pixelů, a tak je potřeba ji vynásobit hodnotou vzdáleností na pixel, 1,365mm/px. Hodnota 1,365mm/px byla poměrem velikosti snímku (na obrázku níže je možno po názvem hodnota $X = 349,44\text{mm}$) a počet pixelů, který činí 256. Snímek byl pro lepší ukázkou zesvětlen, aby byly dobře rozeznatelné jeho hrany.



Obrázek č. 47 Zobrazení snímku v programu MicroDicom

5.4.1 Výsledky měření srdečních parametrů

Tabulka 12-15 shrnují výsledky měření srdečních struktur pro jednotlivé skupiny pacientů. Dále Obrázek č. 48 - č.51 ukazují porovnání měřených parametrů napříč skupinami.

Tabulka 12 Měřené parametry u pacientů se selháním srdce s infarktem

Pacienti se selháním srdce s infarktem				
	Délka [mm]	Šířka [mm]	Obsah [cm ²]	Tloušťka svaloviny [mm]
Pacient 1	50,515	48,269	13,978	11,666
Pacient 2	63,922	54,773	19,861	12,635
Pacient 3	61,028	55,558	19,151	20,090
Pacient 4	52,982	52,276	15,302	16,001
Pacient 5	53,515	48,025	14,319	16,688
Pacient 6	40,193	37,503	5,572	15,890
Pacient 7	50,948	48,129	13,978	14,947
Pacient 8	74,085	72,048	30,426	16,919
Pacient 9	78,474	73,501	33,006	16,066
Pacient 10	59,309	55,656	18,864	9,954
Pacient 11	45,107	37,692	9,596	15,293
Pacient 12	38,157	34,295	7,262	7,262

Tabulka 13 Statistické vlastnosti pro měřené parametry u pacientů se selháním srdce s infarktem

	Rozptyl	Směrodatná odchylka	Dolní kvartil	Medián	Horní kvartil	Interkvartilové rozpětí
Délka	140,644	11,860	46,459	53,249	63,199	16,740
Šířka	138,980	11,789	40,275	50,272	55,632	15,357
Obsah	58,4781	7,647	10,691	14,810	19,683	8,992
Tloušťka svaloviny	6,6059	2,570	13,213	15,945	16,638	3,424

Tabulka 14 Měřené parametry u pacientů se selháním srdce bez infarktu

Pacienti se selháním srdce bez infarktu				
	Délka [mm]	Šířka [mm]	Obsah [cm ²]	Tloušťka svaloviny [mm]
Pacient 13	62,570	58,122	20,175	15,867
Pacient 14	57,833	46,110	15,124	22,635
Pacient 15	50,351	44,159	12,681	11,879
Pacient 16	68,010	58,057	22,127	13,414
Pacient 17	68,113	61,306	23,765	17,265
Pacient 18	61,023	47,664	16,557	16,453
Pacient 19	49,003	38,802	10,592	19,844
Pacient 20	57,818	55,237	15,670	18,460
Pacient 21	56,840	48,161	14,742	11,427
Pacient 22	46,633	43,746	11,452	17,211
Pacient 23	60,507	56,708	19,645	17,464
Pacient 24	76,851	73,644	31,982	15,838

Tabulka 15 Statistické vlastnosti pro měřené parametry u pacientů se selháním srdce bez infarktu

	Rozptyl	Směrodatná odchylka	Dolní kvartil	Medián	Horní kvartil	Interkvartilové rozpětí
Délka	69,361	8,328	51,973	59,170	66,650	14,676
Šířka	85,730	9,259	44,646	51,699	58,106	13,460
Obsah	33,736	5,808	13,196	16,114	21,639	8,443
Tloušťka svaloviny	9,344	3,057	14,020	16,832	18,211	4,191

Tabulka 16 Měřené parametry u pacientů s hypertrofií srdce

Pacienti s hypertrofií				
	Délka [mm]	Šířka [mm]	Obsah [cm ²]	Tloušťka svaloviny [mm]
Pacient 25	40,913	34,603	7,835	24,728
Pacient 26	28,447	26,004	4,054	23,717
Pacient 27	36,807	30,536	6,293	15,425
Pacient 28	37,438	26,310	5,023	19,785
Pacient 29	37,726	31,293	6,456	26,711
Pacient 30	48,743	36,953	10,210	23,944
Pacient 31	45,073	51,624	10,374	20,249
Pacient 32	33,984	27,721	5,259	23,282
Pacient 33	33,615	25,778	4,8321	18,934
Pacient 34	29,652	20,696	3,249	27,202
Pacient 35	38,476	25,111	5,259	17,648

Tabulka 17 Statistické vlastnosti pro měřené parametry u pacientů s hypertrofií srdce


	Rozptyl	Směrodatná odchylka	Dolní kvartil	Medián	Horní kvartil	Interkvartilové rozpětí
Délka	33,423	5,781	33,615	37,438	40,913	7,298
Šířka	33,514	5,789	25,778	27,721	34,603	8,825
Obsah	4,956	2,226	4,832	5,269	7,835	3,003
Tloušťka svaloviny	13,169	3,629	18,934	23,382	24,728	5,794

Tabulka 18 Měřené parametry pacientu se zdravým srdcem


Pacienti se zdravým srdcem				
	Délka [mm]	Šířka [mm]	Obsah [cm ²]	Tloušťka svaloviny [mm]
Pacient 37	37,068	31,136	6,456	13,941
Pacient 38	46,508	44,375	11,835	13,672
Pacient 39	31,159	27,689	4,791	16,090
Pacient 40	50,544	40,918	11,452	12,806
Pacient 41	45,511	34,619	8,832	14,184
Pacient 42	45,434	41,815	10,756	13,149
Pacient 43	35,140	24,755	4,655	12,515
Pacient 44	38,940	31,781	6,689	13,053
Pacient 45	34,290	28,013	5,132	16,837

Tabulka 19 Statistické vlastnosti pro měřené parametry u pacientů se zdravým srdcem


	Rozptyl	Směrodatná odchylka	Dolní kvartil	Medián	Horní kvartil	Interkvartilové rozpětí
Délka	39,330	6,271	34,765	38,940	46,009	11,244
Šířka	43,473	6,593	27,846	31,781	41,366	13,520
Obsah	7,612	2,759	4,962	6,689	11,104	6,143
Tloušťka svaloviny	2,096	1,448	12,874	13,149	15,137	2,2637




Obrázek č. 48 Boxplot délky segmentované srdeční struktury napříč skupinami



Obrázek č. 49 Boxplot šířky segmentované srdeční struktury napříč skupinami



Obrázek č. 50 Boxplot obsahu segmentované srdeční struktury napříč skupinami



Obrázek č. 51 Boxplot tloušťky srdeční svaloviny napříč skupinami


Jak je možné vidět na Obrázek č. 50, největší obsah LV v řezu mají subjekty se selháním srdce, což odpovídá patologii. Dochází k nedostatečné srdeční činnosti a slabému stahu srdce, a proto získaný průměrný obraz vykazuje větší objem srdce u těchto pacientů. Z Obrázek č. 51 je zřejmé, že největší tloušťku srdeční svaloviny můžeme pozorovat u pacientů s hypertrofií. Při porovnání těchto dvou grafů můžeme vidět velkou závislost tloušťky srdeční svaloviny na obsahu levé komory v řezu, a to převážně u pacientů s hypertrofií. Velké rozdíly, mezi minimálními a maximálními hodnotami jednotlivých skupin, jsou způsobeny vysokou variabilitou mezi pacienty. Pacienti po selhání srdce s infarktem a bez infarktu vykazovali největší rozměry dutiny srdeční komory. Toto je srovnatelné s patologií kdy u těchto pacientů dochází k nárůstu objemu srdce, nedostatečné kontrakci svaloviny a k její atrofii což má za důsledek snížení tloušťky svaloviny.

U pacientů se zdravým, normálním, srdcem je obsah komory v řezu poměrně nízký, a to z důvodu, že u zdravého srdce dochází, téměř u všech pacientů, k úplnému stahu srdce a tloušťka srdeční svaloviny zde není nijak změněna.

Tloušťka srdeční svaloviny LV u zdravého srdce se pohybuje v rozmezí 12-14 mm. Při pohledu na výsledky měření tloušťky svaloviny v Tabulka 18 je možné měření hodnotit jako věrohodné.

5.5 Evaluace přesnosti segmentace

Dalším krokem bylo prověřit robustnost segmentace porovnáním s manuálními konturami obsaženými v datasetu. Tyto kontury jsou popsány jejich souřadnicemi, kterou jsou zapsány v tabulce. Pro porovnání těchto kontur je potřeba extrahovat konturu ze segmentovaných snímků. SW prostředí programu MATLAB umožňuje kopírování trasy binární struktury. Pro správné kopírování struktury je potřeba nastavit počáteční bod, který by měl být na hraně struktury a pozadí. Nicméně kvůli velké variabilitě tvaru kontur jednotlivých subjektů je potřeba zavést funkci hledající první jedničkovou hodnotu binárního snímku. Dochází ke skenování matice obrazu, jakmile je hodnota jedna uložena se souřadnice této hodnoty jako počáteční bod pro kopírování kontury. Porovnání kontur bylo provedeno mimo grafické uživatelské rozhraní. V tomto případě se manuální kontury berou jako referenční a provádí se měření následujících parametrů.



Obrázek č. 52 Kontury získané pomocí segmentace (vlevo), vytvořené manuálně expertem

5.5.1 DICE koeficient

Koeficient určuje procentuální podobnost dvou snímků na základě pixelů společných pro oba obrazy. DICE koeficient lze získat pouze z binárních obrazů.

$$D(X, Y) = \frac{2|X \cap Y|}{(|X| + |Y|)} \quad (5)$$

kde X a Y jsou množiny daných obrazů.

5.5.2 Střední kvadratická chyba (MSE)

MSE porovnává dva obrazy na základě druhých mocnin rozdílů střední hodnoty mezi těmito snímky. Hodnoty, které nabývá se pohybují v rozmezí $\langle 0, 1 \rangle$, kdy nula značí, že snímky jsou totožné a jednička opak.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (6)$$

5.5.3 Index korelace

Index korelace udává podobnost dvou obrazů a lineární závislost mezi nimi. Pohybuje se v intervalu $\langle -1, 1 \rangle$ kdy záporná hodnota vyjadřuje zcela nepřímou závislost, kladné hodnoty naopak přímou závislost. Tedy čím vyšší hodnoty tím jsou si snímky podobnější.

5.5.4 Výsledky porovnání s manuálními konturami

Tabulka 20 shrnuje měření parametrů zmíněných v kapitole **Chyba! Nenalezen zdroj odkazů..** Zjištění těchto parametrů bylo provedeno pomocí programu „Test_manualnich_kontur.m“ kdy byla porovnávána segmentovaná kontura ze souborů „Kontura.txt“ s manuální konturou vytvořenou expertem s názvem „Manualni kontura.txt“.

Tabulka 20 Výsledky porovnání segmentovaných struktur s manuálními konturami

	MSE	COR	DICE
Pacient1	0,0186	0,942	0,9099
Pacient2	0,0184	0,9213	0,8722
Pacient 3	0,0303	0,9041	0,8565
Pacient 4	0,0268	0,9079	0,8589
Pacient 5	0,031	0,8937	0,8307
Pacient 6	0,0193	0,9244	0,8785
Pacient 7	0,0252	0,9351	0,9067
Pacient 8	0,0232	0,9385	0,9105
Pacient 9	0,019	0,9557	0,9408
Pacient 10	0,0298	0,9286	0,8999
Pacient 11	0,0408	0,8802	0,8274
Pacient 12	0,0342	0,8779	0,8049
Pacient 13	0,0391	0,9011	0,8636
Pacient 14	0,0442	0,8869	0,8386
Pacient 15	0,0206	0,9307	0,8915
Pacient 16	0,0519	0,8483	0,7784
Pacient 17	0,0366	0,9125	0,8844
Pacient 18	0,0635	0,7958	0,7049
Pacient 19	0,0353	0,9008	0,8506
Pacient 20	0,0151	0,9471	0,9152
Pacient 21	0,045	0,8813	0,8242

Pacient 22	0,0526	0,8102	0,7129
Pacient 23	0,0381	0,9079	0,8808
Pacient 24	0,0329	0,9167	0,8781
Pacient 25	0,0391	0,8373	0,7482
Pacient 26	0,0128	0,8549	0,7458
Pacient 27	0,0215	0,8755	0,7974
Pacient 28	0,0635	0,7093	0,5698
Pacient 29	0,0384	0,797	0,6873
Pacient 30	0,0379	0,7902	0,6792
Pacient 31	0,0224	0,8898	0,8215
Pacient 32	0,033	0,8235	0,711
Pacient 33	0,0219	0,8686	0,7849
Pacient 34	0,0247	0,8236	0,7188
Pacient 35	0,0164	0,8534	0,7566
Pacient 36	---	---	---
Pacient 37	0,0282	0,8593	0,773
Pacient 38	0,0103	0,9655	0,945
Pacient 39	0,0157	0,8741	0,7884
Pacient 40	0,019	0,934	0,8966
Pacient 41	0,0336	0,851	0,7666
Pacient 42	0,033	0,8718	0,7942
Pacient 43	0,0206	0,8184	0,7084
Pacient 44	0,0244	0,8642	0,7807
Pacient 45	0,0376	0,8009	0,6726
Intervaly	$\langle 0,0103; 0,0635 \rangle$	$\langle 0,5698; 0,945 \rangle$	$\langle 0,7093; 0,9655 \rangle$

Dle vlastností koeficientů popsaných v kapitolách 5.5.1, 5.5.2 a 5.5.3 a získaných hodnot je možné vidět vysokou robustnost navrhované metody. Průměrné hodnoty jednotlivých koeficientů pak jsou: MSE = 0,0306, korelační koeficient COR = 0,8775 a DICE = 0,8016. Tedy by se dalo říct, že podobnost s manuálními konturami na základě DICE koeficientu se pohyboval okolo 80 %. U pacienta č. 36 se nepodařilo provést segmentaci, a to z důvodu rozdílného jasu na snímcích MOLLI sekvence, oproti ostatním pacientům a následného předzpracování. Proto pro něj nebyly změřeny odpovídající parametry.

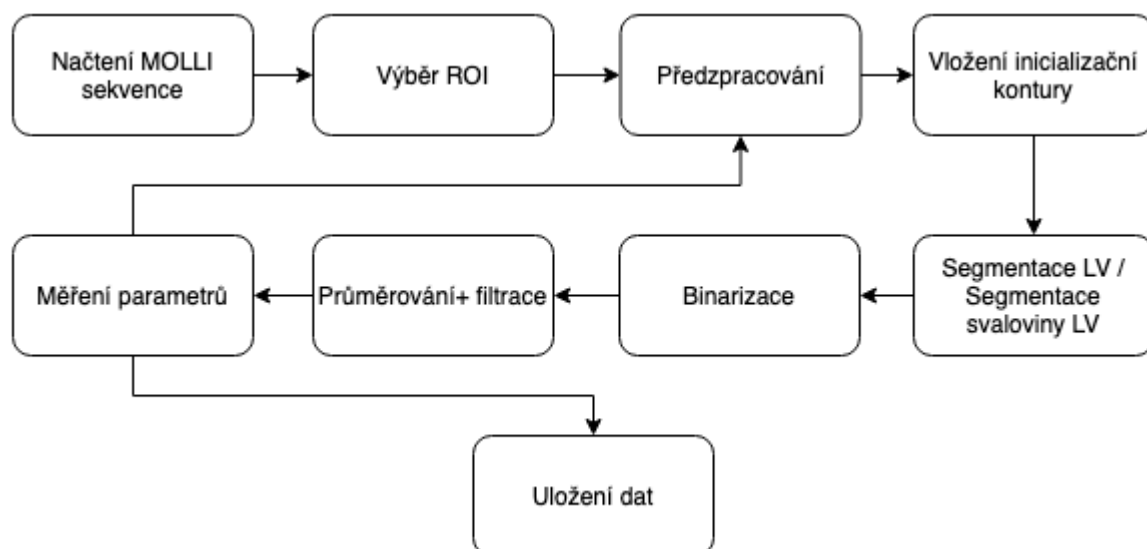
5.6 Výpočetní náročnost

Testování bylo provedeno v prostředí MATLAB na počítači s procesorem AMD ryzen 3 2200G a 8 GB RAM. Segmentace pomocí aktivních kontur je poměrně výpočetně náročná metoda. Nicméně z důvodu nízkého počtu pixelů, ze kterého je tvořena vybraná oblast zájmu trvala segmentace jedné MOLLI sekvence v řádech minut. Hlavními parametry, které ovlivňují rychlost segmentace jsou tedy: rozlišení segmentovaného obrazu, a to z důvodu, že při každé iteraci dochází k výpočtu integrace v celém obrazu, počet iterací a velikost počáteční kontury. Velkou roli samozřejmě hraje i výkonost zařízení.

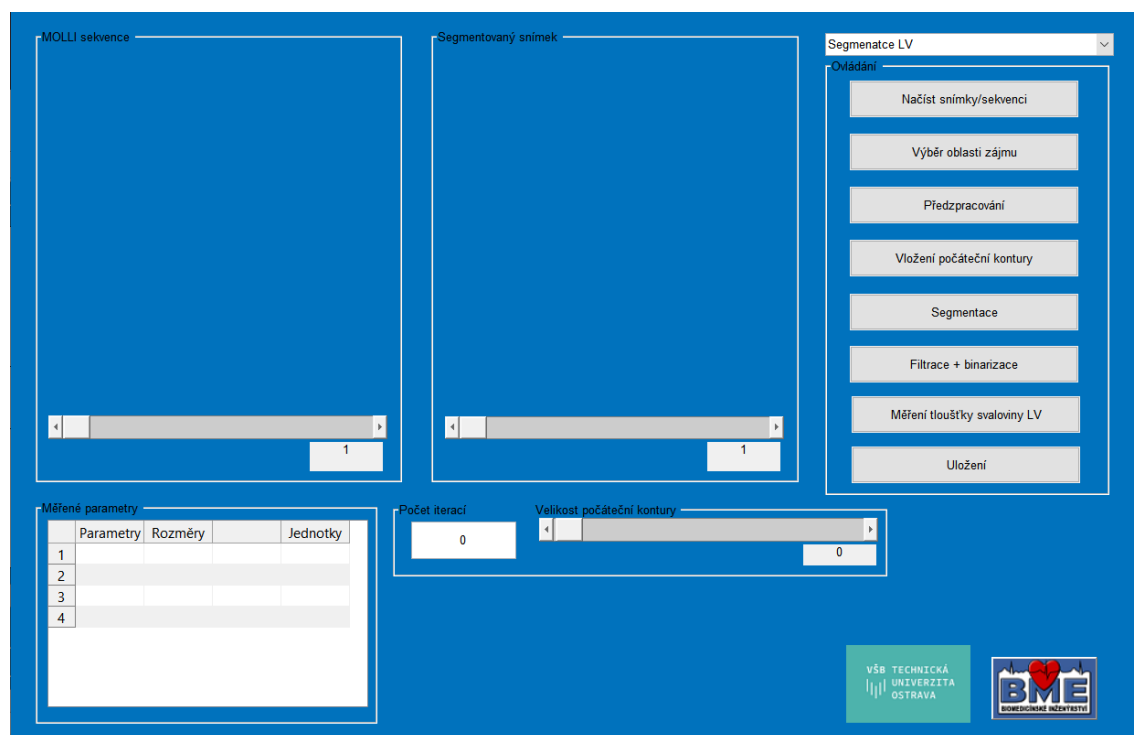
Celkový proces od načtení dat po konečné měření a uložení výsledků pro jednu MOLLI sekvenci se pohyboval okolo 4 minut v případě správně zvolených parametrů kontury jako velikost a poloha iniciační kontury a počet iterací. Tento čas se měnil v řádech vteřin v závislosti na dané patologii. Například u pacientů s hypertrofií, kdy byla potřeba použít menší iniciační konturu a vyšší počet iterací se čas pohyboval okolo tří a půl minuty.

6. Graficko-uživatelské rozhraní (GUI)

Další částí této diplomové práce bylo navrhnout graficko-uživatelské rozhraní pro segmentaci srdečních struktur z MOLLI sekvencí. K návrhu rozhraní sloužil toolbox GUIDE v prostředí MATLAB. V této kapitole budou dále popsány jednotlivé prvky rozhraní. Funkce GUI je popsána na diagramu níže.



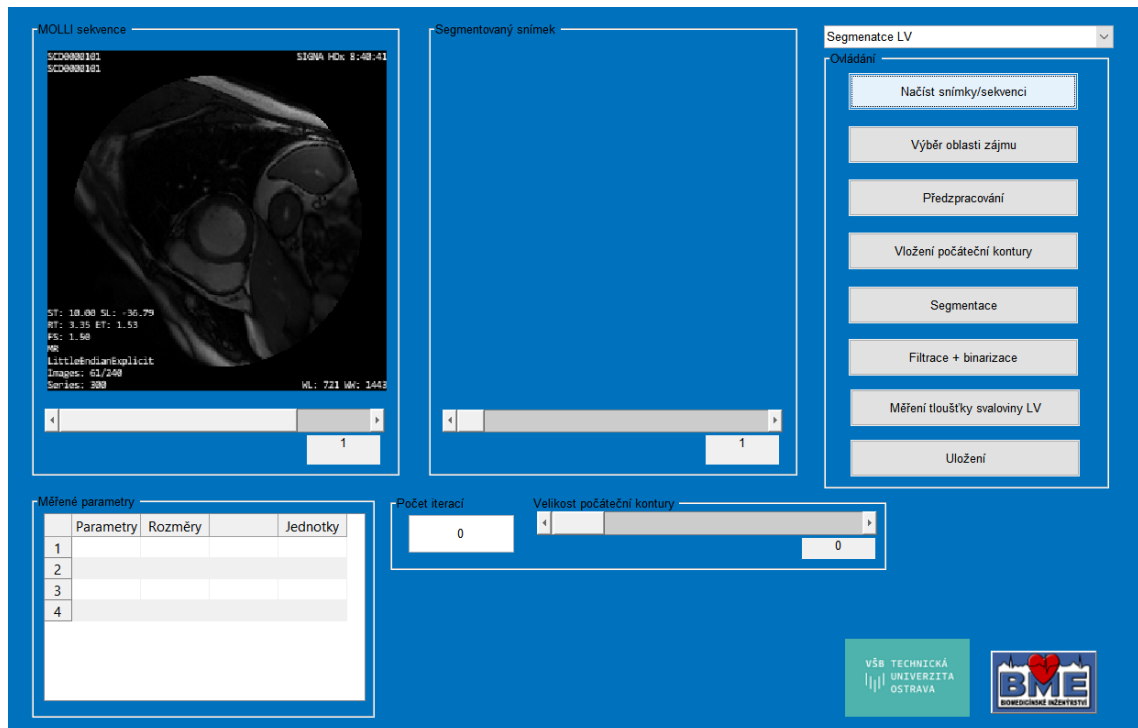
Obrázek č. 53 Diagram funkce GUI



Obrázek č. 54 Graficko-uživatelské rozhraní

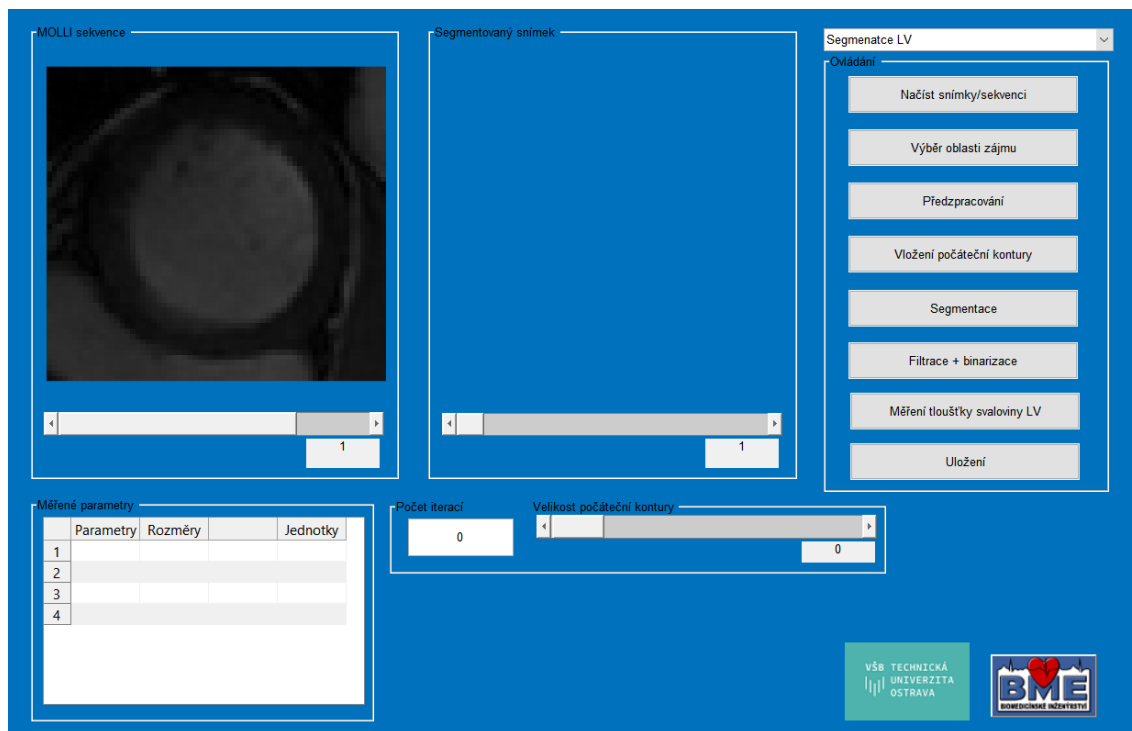
Jak je možné vidět na Obrázek č. 54 je rozhraní strukturálně rozděleno na dvě okna s posuvníkem zobrazující snímky jednotlivé snímky, ovládací panel, okno s tabulkou měřených parametrů a posuvník a editovací ono pro úpravu aktivní kontury.

Prvním krokem je načtení dat. Načtení dat se provádí pomocí prvku „Načíst snímky/sekvenci“. Po výběru dojde k otevření dialogového okna, pomocí kterého je možné najít odpovídající MOLLI sekvenci určenou k segmentaci. Rozhraní pracuje s formáty .jpg, .jpeg, .bmp, .png, .PNG. Po výběru sekvence snímků je uživatel přesměrován na rozhraní. V levém okně se zobrazí první snímek ze sekvence, jak je zobrazeno na Obrázek č. 55. Posuvník následně slouží pro zobrazení ostatních snímků.




Obrázek č. 55 Zobrazení prvního snímku sekvence po jejím načtení.

Dalším krokem je výběr oblasti zájmu. Pro tuto možnost slouží prvek „Výběr oblasti zájmu“. Tento prvek umožní pomocí kurzoru vybrat oblast zájmu. Vybraná oblast se následně zobrazí na stejném místě jako načtené snímky. Výsledek je zobrazen na Obrázek č. 56. Tento krok lze přeskočit a je možné provádět segmentaci na původních snímcích. Tato možnost ovšem způsobí zpomalení celkové segmentace z důvodu většího rozlišení snímku a nutnosti jeho přepočtu při každé iteraci.



Obrázek č. 56 Rozhraní s vybraným ROI

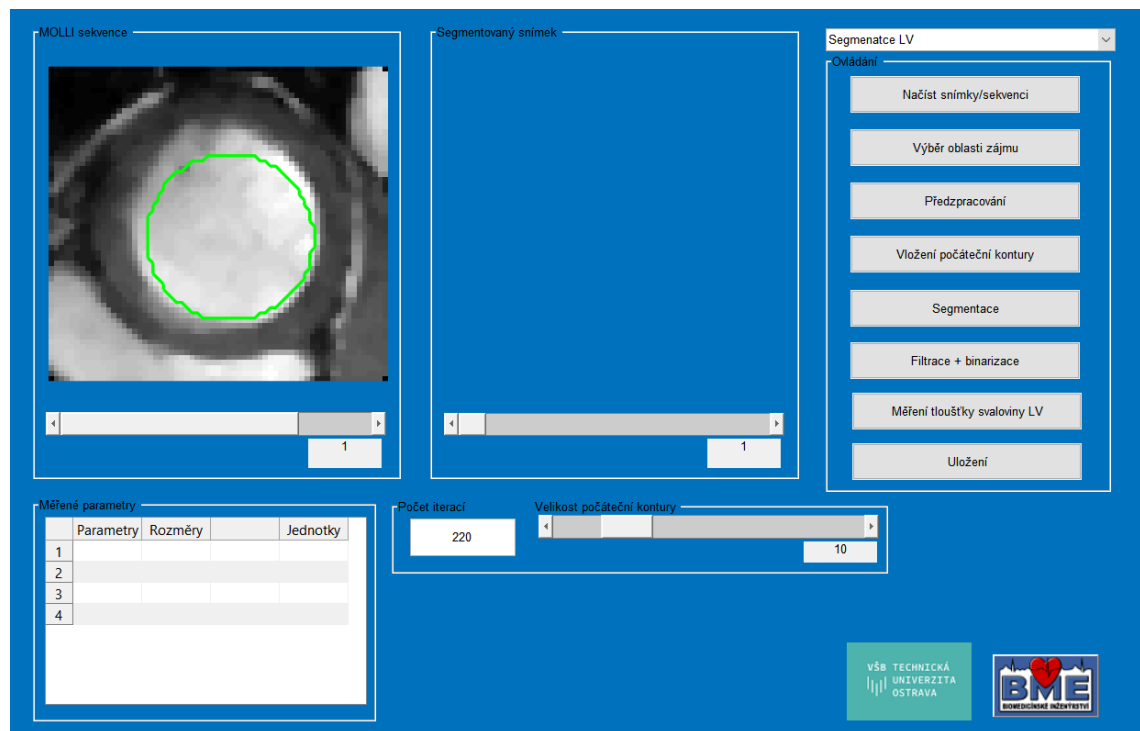
Po výběru oblasti zájmu nastává předzpracování obrazu. Na sekvenci oblastí zájmu se aplikuje jasová transformace a mediánový filtr, jak je popsáno v kapitole 4.2.



Obrázek č. 57 Výsledný obraz po předzpracování


Jak již bylo zmíněno v kapitole 5.2 pro správnou segmentaci je potřeba vložit iniciační konturu. K tomu slouží prvek „Vložení počáteční kontury“. Počáteční konturu je možné upravit, a to pomocí posuvníku s názvem „Velikost počáteční kontury“ a editovacího okna s názvem „počet iterací“. Pro segmentaci dutiny LV je lepší použít menší konturu a vyšší počet iterací kdežto pro segmentaci

svaloviny LV naopak větší konturu, která přilehne k okraji srdeční svaloviny, a menší počet iterací. Na Obrázek č. 58 můžeme vidět vloženou počáteční konturu.



Obrázek č. 58 Rozhraní s vloženou počáteční konturou o velikosti 10

Prvek „Segmentace“ provede segmentaci napříč všemi načtenými snímky. Segmentace využívá stejnou počáteční konturu, proto je potřeba dbát velký důraz na správné nastavení velikosti a počtu iterací, aby nedocházelo k nekvalitní segmentaci. Po provedení segmentace se v okně „Segmentovaný snímek“ zobrazí segmentované regiony jednotlivých struktur. Tyto regiony jsou binarizované tedy dutina LV má hodnotu jedna a okolí hodnotu nula. Příklad jde vidět na Obrázek č. 59.



Obrázek č. 59 Rozhraní po provedení segmentace

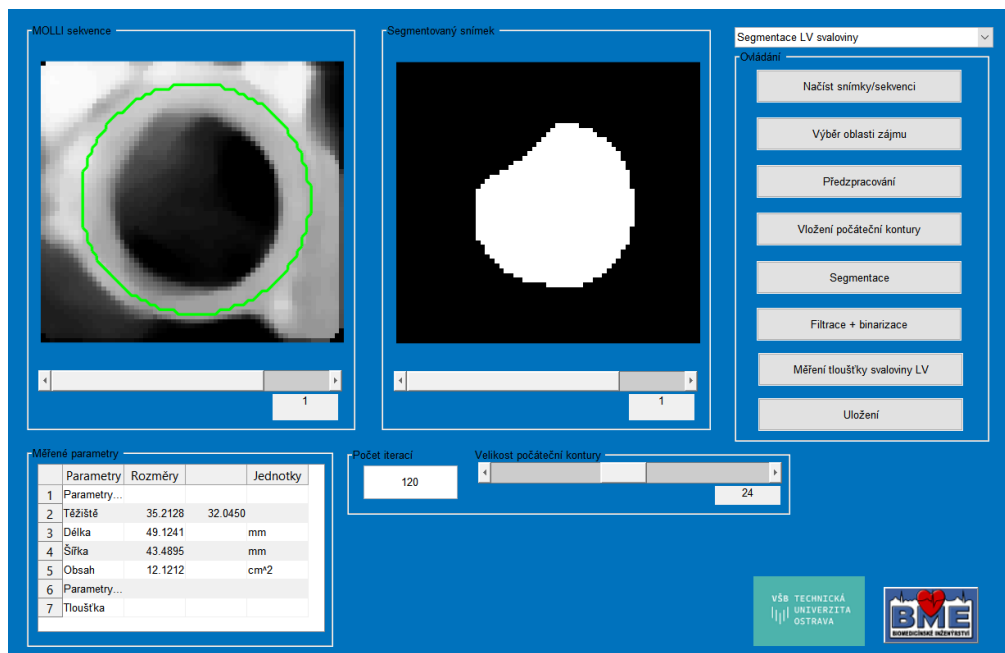
Pro nalezení rozměrů v daném řezu je potřeba snímky zprůměrovat. Případně odfiltrovat nežádoucí segmentované složky. K tomu slouží prvek „Filtrace + binarizace“. Princip je popsán v kapitole 5.3. Po filtraci a průměrování snímku dojde k výpočtu její parametrů, jak je popsáno v kapitole 5.4. V tomto kroku se změří pouze parametry dutiny LV, které se následně vypíší do tabulky „Měřené parametry“ jak je možno vidět na obrázku níže.

Měřené parametry				
	Parametry	Rozměry		Jednotky
1	Parametry...			
2	Těžiště	35.2128	32.0450	
3	Délka	49.1241		mm
4	Šířka	43.4895		mm
5	Obsah	12.1212		cm ²
6	Parametry...			
7	Tloušťka			


Obrázek č. 60 Zápis parametrů dutiny LV do tabulky

Dalším krokem je segmentace svaloviny LV. Segmentace probíhá na stejných snímcích jako při segmentaci dutiny LV. Celý proces se liší pouze v natavení parametrů kontury a prvotním předpracování. Aby bylo možné segmentovat svalovinu LV je potřeba provést změnu v rolovacím okně

nahoře vpravo. Následně po volbě předpracování se zobrazí Předpracovaný obraz, na který je potřeba vložit počáteční kontur. Jak již bylo zmíněno je lepší použít větší konturu, která lépe kopíruje vnější stranu srdeční svaloviny. Předpracování a počáteční kontura je možná vidět na Obrázek č. 61. Výsledné snímky po segmentaci a následné binarizaci je možné vidět na Obrázek č. 62 a Obrázek č. 63.



Obrázek č. 61 Předpracování a iniciační kontura při segmentaci srdeční svaloviny



Obrázek č. 62 Výsledek segmentace srdeční svaloviny



Obrázek č. 63 Výsledek srdeční svaloviny po binarizaci a odečtení segmentované dutiny.

Po segmentaci srdeční svaloviny je potřeba změřit její tloušťku k tomu slouží prvek „Měření tloušťky svaloviny LV“. Po této volbě je možné pomocí pohyblivého kurzoru zvolit dva body mezi kterými se bude vzdálenost měřit. Výsledek je pak zapsán do tabulky na poslední řádek, jak je možno vidět na Obrázek č. 64.

Měřené parametry			
	Parametry	Rozměry	Jednotky
1	Parametry...		
2	Těžiště	35.2128	32.0450
3	Délka	49.1241	mm
4	Šířka	43.4895	mm
5	Obsah	12.1212	cm^2
6	Parametry...		
7	Tloušťka	17.6454	mm

Obrázek č. 64 Výsledná tabulka měřených parametrů

Posledním prvkem je „Uložení“ po volbě tohoto prvku se otevře dialogové okno, které umožní výběr lokace pro uložení dat. Uloží se jak obě segmentované struktury ve formátu .png, tabulka s naměřenými daty ve formátu .xlsx a segmentovaná kontura jako tabulka souřadnic ve formátu .txt. Tabulka s naměřenými parametry a souřadnicemi kontury pak slouží pro další zpracování. Příklad výsledků je pak zobrazen na Obrázek č. 65-67.



Obrázek č. 65 Příklad výsledných uložených snímků segmentované srdeční struktury, vlevo dutina LV, vpravo svalovina LV

	A	B	C	D	E
1	Parametry LV				
2	Těžiště	34,92773	34,58691		
3	Délka	50,51504		mm	
4	Šířka	48,26871		mm	
5	Obsah	13,9776		cm^2	
6	Parametry svaloviny LV				
7	Tloušťka	11,66586		mm	
8					

Obrázek č. 66 Příklad uložené tabulky měřených parametrů v soboru .xlsx

31,17
30,18
29,18
28,18
27,19
26,19
25,20
25,21
24,22
23,23
22,24
21,25
21,26
21,27
20,28

Obrázek č. 67 Příklad části uložených souřadnic kontury dutiny LV

7. Závěr

Úkolem této práce byl návrh segmentačního algoritmus pro detekci myokardu na MR snímcích, registračního algoritmu pro MOLLI sekvence a realizace graficko-uživatelského rozhraní. Oba algoritmy byly navrženy v prostředí MATLAB. Pro Graficko-uživatelské rozhraní byl použit toolbox GUIDE. V první části bylo potřeba nastudovat segmentační metody pro detekci myokardu. Na základě této studie byla použita Level-set metoda využívající lokální Gaussovu distribuci. Nastavení algoritmu proběhlo na základě informací získaných ze studie a doladěno díky testování na sadě dat. Datová sada obsahoval 45 subjektů, kde pro každý subjekt byly nasnímány snímky z pohledu dvou a čtyř komor z krátké a dlouhé osy. Pro účely testování byly zvoleny snímky z pohledu krátké osy se zaměřením na levou komoru. Pro každý subjekt bylo dále vybráno 20 snímků reprezentující MOLLI sekvenci. Z dat byla nejdříve vybrána oblast zájmu a následně se provedlo předzpracování pomocí jasových transformací a mediánového filtru popsaných v kapitole 4.2. Po aplikaci segmentace na předpracovaná data bylo potřeba aplikovat registrační algoritmus a finální filtraci, ve formě mediánového filtru, pro odstranění okolních struktur. Z výsledných segmentací byl následně extrahovaný binární model, na kterém bylo provedeno měření srdečních parametrů. Finálním krokem bylo porovnat segmentovanou strukturu s manuálními segmentacemi, které jsou součástí datové sady. To bylo docíleno extrakcí tabulky souřadnic segmentované dutiny levé komory testováním na základě podobnosti pomocí korelačního a DICE koeficientu a Střední kvadratické chyby MSE. Všechny výsledky jsou zapsány do Tabulka 12 Měření parametry u pacientů se selháním srdce s infarktema vyobrazeny na příslušných grafech.

Dle výsledků je možné konstatovat správnost měřených parametrů, a to na základě měřených parametrů u pacientů se zdravým srdcem. Na základě DICE koeficientu se průměrná podobnost jednotlivých segmentovaných kontur s manuálními konturami pohybovala okolo 80 %. Korelace pak vykazovala vysokou až úplnou podobnost mezi těmito segmentacemi. Střední kvadratická chyba MSE byla minimální. Správnost segmentace mohla ovlivnit skutečnost výskytu papilárních svalů a to, že papilární svaly byly přiřazeny svalovině srdeční komory.

Finálním výstupem bylo graficko-uživatelské rozhraní které umožňuje jednoduchý postup při segmentaci srdečních struktur z MOLLI sekvencí a uložení měřených parametrů či dat pro další zpracování.

8. Zdroje

- [1] PLEVA, Martin, Jiří WEICHET, Tomáš PALEČEK, Jan BAXA, Theodor ADLA, Dana KAUTZNEROVÁ a Šárka BOHATÁ. Clinical Indications and Time Schedule for Cardiac Magnetic Resonance Imaging. A Joint Expert Opinion of the Czech Society of Cardiology and Czech Radiological Society of the Czech Medical Society of J.E. Purkyne. *Cor et Vasa* [online]. 2018, **60**(6), e649-e653 [cit. 2020-01-01]. DOI: 10.1016/j.crvasa.2018.03.007. ISSN 00108650.
- [2] SOSIN, M D, H R KHAN, J J TOTMAN a K S POINTON. Review of clinical cardiac MRI. *Imaging* [online]. 2013, **22**(1) [cit. 2020-01-01]. DOI: 10.1259/imaging.20110004. ISSN 0965-6812.
- [3] JO, Yeseul, JeongJae KIM, Chul Hwan PARK, et al. Guideline for Cardiovascular Magnetic Resonance Imaging from the Korean Society of Cardiovascular Imaging—Part 1: Standardized Protocol. *Korean Journal of Radiology* [online]. 2019, **20**(9) [cit. 2020-01-02]. DOI: 10.3348/kjr.2019.0398. ISSN 1229-6929.
- [4] Partition.jpg. In: *Wikipedia* [online]. San Francisco, USA: Wikimedia Foundation, 2001 [cit. 2020-01-02]. Dostupné z: https://en.wikipedia.org/wiki/Split_and_merge_segmentation#/media/File:Partition.jpg
- [5] T.N. Shewaye, Cardiac MR Image Segmentation Techniques: an overview, <http://arxiv.org/pdf/1502.04252.pdf> (2015)
- [6] Nag, Sayan. 2017. “Image Registration Techniques: A Survey.” engrXiv. November 28. doi:10.31224/osf.io/rv65c.
- [7] KETTER, Wolfgang, John COLLINS, Maria GINI, Alok GUPTA a Paul SCHRATER. Identifying and Forecasting Economic Regimes in TAC SCM. *Agent-Mediated Electronic Commerce. Designing Trading Agents and Mechanisms* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2006, 2006, , 113-125 [cit. 2020-01-04]. Lecture Notes in Computer Science. DOI: 10.1007/11888727_9. ISBN 978-3-540-46242-2.
- [8] PLEVA, Martin a Petr OUŘEDNÍČEK. *MRI srdce: praktické využití z pohledu kardiologa*. Praha: Grada, 2012. ISBN 978-80-247-3931-1.
- [9] RIEGLER, Johannes, King K. CHEUNG, Yiu Fung MAN, Jon O. CLEARY, Anthony N. PRICE a Mark F. LYTHGOE. Comparison of segmentation methods for MRI measurement of cardiac function in rats. *Journal of Magnetic Resonance Imaging* [online]. 2010, **32**(4), 869-877 [cit. 2020-01-04]. DOI: 10.1002/jmri.22305. ISSN 10531807.

- [10] BENAMEUR, Narjes, Enrico Gianluca CAIANI, Martino ALESSANDRINI, Younes AROUS, Nejmeddine BEN ABDALLAH, Foued SAADAOUÏ a Tarek KRAIEM. Left ventricular MRI wall motion assessment by monogenic signal amplitude image computation. *Magnetic Resonance Imaging* [online]. 2018, **54**, 109-118 [cit. 2020-01-04]. DOI: 10.1016/j.mri.2018.08.004. ISSN 0730725X.
- [11] YILMAZ, Pinar, Karel WALLECAN, Wisnumurti KRISTANTO, Jean-Paul ABEN a Adriaan MOELKER. Evaluation of a Semi-automatic Right Ventricle Segmentation Method on Short-Axis MR Images. *Journal of Digital Imaging* [online]. 2018, **31**(5), 670-679 [cit. 2020-01-04]. DOI: 10.1007/s10278-018-0061-3. ISSN 0897-1889.
- [12] WANG, Yan, Yue ZHANG, Wanling XUAN, et al. Fully automatic segmentation of 4D MRI for cardiac functional measurements. *Medical Physics* [online]. 2019, **46**(1), 180-189 [cit. 2020-01-05]. DOI: 10.1002/mp.13245. ISSN 00942405.
- [13] LIU, Jie, Xiahai ZHUANG, Hongzhi XIE, Shuyang ZHANG a Lixu GU. Myocardium segmentation from DE MRI with guided random walks and sparse shape representation. *International Journal of Computer Assisted Radiology and Surgery* [online]. 2018, **13**(10), 1579-1590 [cit. 2020-01-05]. DOI: 10.1007/s11548-018-1817-4. ISSN 1861-6410.
- [14] MAKOWSKI, Piotr, Thomas Sangild SØRENSEN, Søren Vorre THERKILDSEN, Andrzej MATERKA, Hans STØDKILDE-JØRGENSEN a Erik Morre PEDERSEN. Two-phase active contour method for semiautomatic segmentation of the heart and blood vessels from MRI images for 3D visualization. *Computerized Medical Imaging and Graphics* [online]. 2002, **26**(1), 9-17 [cit. 2020-01-05]. DOI: 10.1016/S0895-6111(01)00026-X. ISSN 08956111.
- [15] BARBA-J, Leiner, Boris ESCALANTE-RAMÍREZ, Enrique VALLEJO VENEGAS a Fernando ARÁMBULA COSÍO. *A 3D Hermite-based multiscale local active contour method with elliptical shape constraints for segmentation of cardiac MR and CT volumes* [online]. 2018, **56**(5), 833-851 [cit. 2020-01-05]. DOI: 10.1007/s11517-017-1732-9. ISSN 0140-0118.
- [16] OKSUZ, Ilkay, Anirban MUKHOPADHYAY, Rohan DHARMAKUMAR a Sotirios A. TSAFTARIS. Unsupervised Myocardial Segmentation for Cardiac BOLD. *IEEE Transactions on Medical Imaging* [online]. 2017, **36**(11), 2228-2238 [cit. 2020-01-05]. DOI: 10.1109/TMI.2017.2726112. ISSN 0278-0062.
- [17] JEROSCH-HEROLD, Michael a Raymond Y. KWONG. Cardiac T1 Imaging. *Topics in Magnetic Resonance Imaging* [online]. 2014, **23**(1), 3-11 [cit. 2020-01-05]. DOI: 10.1097/RMR.000000000000013. ISSN 0899-3459.
- [18] MASUTANI, Evan M., Francisco CONTIJOCH, Espoir KYUBWA, Joseph CHENG, Marcus T. ALLEY, Shreyas VASANAWALA a Albert HSIAO. Volumetric segmentation-free method for rapid visualization of vascular wall shear stress using 4D flow MRI. *Magnetic Resonance in*

Medicine [online]. 2018, **80**(2), 748-755 [cit. 2020-01-06]. DOI: 10.1002/mrm.27159. ISSN 07403194.

- [19] Sphx_glr_plot_thresholding_003.png. In: *Scikit-image: image processing in Python* [online]. Stéfan van der Walt, 2009 [cit. 2020-01-06]. Dostupné z: https://scikit-image.org/docs/dev/_images/sphx_glr_plot_thresholding_003.png
- [20] The stationary level set function. In: *Math.berkeley* [online]. Berkeley, California 94720, 2006 [cit. 2020-04-03].
- [21] ROUGER, Melisande. ECR 2013 Focus: Organs From A to Z: Heart. *European society of radiology blog* [online]. 19.02.2013, 2013, 1 [cit. 2020-04-15].
- [22] Příspěvatelé WikiSkript, *Srdeční selhání (patologie)* [online], , c2018, Datum poslední revize 11. 11. 2018, 07:14 UTC, [citováno 15. 04. 2020] <[https://www.wikiskripta.eu/index.php?title=Srde%C4%8Dn%C3%AD_selh%C3%A1n%C3%AD_\(patologie\)&oldid=416099](https://www.wikiskripta.eu/index.php?title=Srde%C4%8Dn%C3%AD_selh%C3%A1n%C3%AD_(patologie)&oldid=416099)>
- [23] WANG, Li, Lei HE, Arabinda MISHRA a Chunming LI. Active contours driven by local Gaussian distribution fitting energy. *Signal Processing* [online]. 2009, **89**(12), 2435-2447 [cit. 2020-04-16]. DOI: 10.1016/j.sigpro.2009.03.014. ISSN 01651684.

Seznam příloh

Příloha I


Příloha A: Výsledky segmentace – snímky

Příloha B: Výsledky segmentace – Tabulky parametrů, extrahované kontury (.txt), manuální kontury


Příloha II

Vypracované kódy, GUI


Příloha A




Obrázek č. 68 Výsledky pro pacienti po selhání srdce s infarktem. Sestupně pacient 1-5



Obrázek č. 69 Výsledky pro pacienty po selhání srdce bez infarktem. Sestupně pacient 13-17



Obrázek č. 70 Výsledky pro pacienty trpící hypertrofií. Sestupně pacient 25-29



Obrázek č. 71 Výsledky pro pacienty se zdravým srdcem. Sestupně pacient 37-41

Příloha B

Tabulka 21 Výsledné měřené parametry pro pacienty po selhání srdce s infarktem

Pacienti se selháním srdce s infarktem				
	Délka [mm]	Šířka [mm]	Obsah [cm ²]	Tloušťka svaloviny [mm]
Pacient 1	50,515	48,269	13,978	11,666
Pacient 2	63,922	54,773	19,861	12,635
Pacient 3	61,028	55,558	19,151	20,090
Pacient 4	52,982	52,276	15,302	16,001
Pacient 5	53,515	48,025	14,319	16,688
Pacient 6	40,193	37,503	5,572	15,890
Pacient 7	50,948	48,129	13,978	14,947
Pacient 8	74,085	72,048	30,426	16,919
Pacient 9	78,474	73,501	33,006	16,066
Pacient 10	59,309	55,656	18,864	9,954
Pacient 11	45,107	37,692	9,596	15,293
Pacient 12	38,157	34,295	7,262	7,262

Tabulka 22 Výsledné měřené parametry pro pacienty po selhání srdce bez infarktu

Pacienti se selháním srdce bez infarktu				
	Délka [mm]	Šířka [mm]	Obsah [cm ²]	Tloušťka svaloviny [mm]
Pacient 13	62,570	58,122	20,175	15,867
Pacient 14	57,833	46,110	15,124	22,635
Pacient 15	50,351	44,159	12,681	11,879
Pacient 16	68,010	58,057	22,127	13,414
Pacient 17	68,113	61,306	23,765	17,265
Pacient 18	61,023	47,664	16,557	16,453
Pacient 19	49,003	38,802	10,592	19,844
Pacient 20	57,818	55,237	15,670	18,460
Pacient 21	56,840	48,161	14,742	11,427
Pacient 22	46,633	43,746	11,452	17,211
Pacient 23	60,507	56,708	19,645	17,464
Pacient 24	76,851	73,644	31,982	15,838

Tabulka 23 Výsledné měřené parametry pro pacienty s hypertrofií

Pacienti s hypertrofií				
	Délka [mm]	Šířka [mm]	Obsah [cm ²]	Tloušťka svaloviny [mm]
Pacient 25	40,913	34,603	7,835	24,728
Pacient 26	28,447	26,004	4,054	23,717
Pacient 27	36,807	30,536	6,293	15,425
Pacient 28	37,438	26,310	5,023	19,785
Pacient 29	37,726	31,293	6,456	26,711
Pacient 30	48,743	36,953	10,210	23,944
Pacient 31	45,073	51,624	10,374	20,249
Pacient 32	33,984	27,721	5,259	23,282
Pacient 33	33,615	25,778	4,8321	18,934
Pacient 34	29,652	20,696	3,249	27,202
Pacient 35	38,476	25,111	5,259	17,648

Tabulka 24 Výsledné měřené parametry pro pacienty se zdravým srdcem

Pacienti se zdravým srdcem				
	Délka [mm]	Šířka [mm]	Obsah [cm ²]	Tloušťka svaloviny [mm]
Pacient 37	37,068	31,136	6,456	13,941
Pacient 38	46,508	44,375	11,835	13,672
Pacient 39	31,159	27,689	4,791	16,090
Pacient 40	50,544	40,918	11,452	12,806
Pacient 41	45,511	34,619	8,832	14,184
Pacient 42	45,434	41,815	10,756	13,149
Pacient 43	35,140	24,755	4,655	12,515
Pacient 44	38,940	31,781	6,689	13,053
Pacient 45	34,290	28,013	5,132	16,837